De la idea al modelo estructural:

Investigación conceptual en ciencias de la administración

Juan Mejía Trejo

AMIDI
Scientia et Praxis

De la idea al modelo estructural: Investigación conceptual en ciencias de la administración

Juan Mejía Trejo

Este libro fue sometido a un proceso de dictamen por pares doble ciego de acuerdo con las normas establecidas por el Comité Editorial de la Academia Mexicana de investigación y Docencia en Innovación (AMIDI)

Esta obra se encuentra bajo la licencia Atribución-No Comercial-Sin Derivadas 4.0 (CC BY- NC-ND 4.0), de Creative Commons. Usted puede descargar esta obra y distribuir en cualquier medio o formato dando crédito a los autores, pero no se permite su uso comercial ni la generación de obras derivadas.

Primera edición, 2026
D.R. © Academia Mexicana de Investigación y Docencia en Innovación (AMIDI)
Av. Paseo de los Virreyes 920.
Col. Virreyes Residencial
C.P. 45110, Zapopan, Jalisco

Nota editorial.
La autoría, revisión final y responsabilidad intelectual de esta obra corresponden exclusivamente al autor.

ISBN: 978-970-96061-3-3

Hecho y editado en México
Made and edited in Mexico

Scientia et Praxis

AMIDI
Academia Mexicana
de Investigación y Docencia
en Innovación

Sobre el autor

Juan Mejía Trejo
Universidad de Guadalajara, CUCEA, Jalisco, México
ORCID: https://orcid.org/0000-0003-0558-1943
Correo: jmejia@cucea.udg.mx

Doctor en Ciencias Administrativas y profesor investigador del Centro Universitario de Ciencias Económico Administrativas (CUCEA) de la Universidad de Guadalajara (UdeG). Su trayectoria se centra en administración de la innovación, modelos de negocio, innovación para el desarrollo sostenible y aplicaciones de la inteligencia artificial.

Índice

Sobre el autor iv
INTRODUCCIÓN 1
CAPÍTULO 1. La idea antes del modelo 5
- De la idea al fenómeno investigable 7
- Del fenómeno al problema estructural 13
- De la pregunta a la relación estructural 18
- De los conceptos a las variables y constructos 24
- Viabilidad conceptual, empírica y metodológica del estudio 31
- Conclusiones 36

CAPÍTULO 2. Sistema conceptual y lógica del modelo 44
- Del problema de investigación al sistema conceptual 45
- Tipos de vacío: teórico, empírico, metodológico y práctico 53
- Explicación, predicción y lógica del modelo 58
- Relaciones conceptuales: antecedentes, consecuencias y mecanismos 64
- Construcción del sistema conceptual preliminar antes del modelo SEM 70
- Conclusiones 76

CAPÍTULO 3. De la teoría a las variables 83
- De la teoría al marco relacional 85
- Variable dependiente y variables explicativas 91
- Panorama de las técnicas SEM y lógica de modelación estructural 95
- Hipótesis del modelo: contraste, significancia y apoyo empírico 110
- Representación gráfica, trazabilidad y coherencia interna del modelo estructural ... 117
- Conclusiones 124

CAPÍTULO 4. Del concepto al constructo medible 135
- Concepto, variable, constructo 136
- Constructos latentes y variables observables 144
- Dimensionalidad del constructo 149
- Desarrollo inicial de escala 155
- Especificación conceptual antes de medir 163
- Conclusiones 168

CAPÍTULO 5. PLS-SEM, del constructo al indicador 173
- Constructos reflectivos, formativos, compuestos y jerárquicos 175
- Confiabilidad y validez convergente en constructos reflectivos 180
- Validez discriminante y diferenciación empírica entre constructos 186
- Colinealidad, sesgo de método común y calidad de los indicadores 194
- Tamaño de muestra, potencia estadística y viabilidad del modelo 203
- Conclusiones 209

CAPÍTULO 6. Robustez, mediación, moderación, MICOM, MGA y reporte 214
Robustez y estabilidad del modelo estructural 216
Mediación, moderación y efectos complejos en PLS-SEM 229
Invariancia y análisis multigrupo en PLS-SEM 240
Evaluación del poder predictivo del modelo 248
Comparación de modelos 257
Conclusiones 270
CAPÍTULO 7. Del modelo SEM al producto de investigación 279
Fin del proceso: de la idea al modelo evaluado 281
Construcción del modelo SEM como producto científico 289
Apartado metodológico para tesis, artículo o capítulo de libro 296
Presentación e interpretación de resultados SEM/PLS-SEM 304
Discusión, contribuciones, limitaciones y futuras líneas de investigación 311
Conclusiones 318
REFERENCIAS 328

INTRODUCCIÓN

La investigación en ciencias de la administración enfrenta un desafío metodológico recurrente: muchos estudios desean aplicar modelos de ecuaciones estructurales, utilizar PLS-SEM, contrastar hipótesis o reportar indicadores de validez, confiabilidad, predicción y robustez, pero no siempre construyen con suficiente claridad la ruta previa que permite llegar a un modelo científicamente defendible. Con frecuencia, el investigador inicia desde el software, desde una base de datos o desde una lista de variables tomadas de la literatura, sin haber delimitado con precisión la idea, el fenómeno, el problema, la pregunta estructural, los constructos, los indicadores y la lógica relacional que sostendrá el análisis. Este punto es decisivo porque un modelo SEM/PLS-SEM no se justifica por la cantidad de flechas, coeficientes o índices que produce, sino por la coherencia acumulada entre el problema, la teoría, la medición, la estimación, la interpretación y la comunicación académica.

Vacío que atiende el libro. El vacío central de esta obra se ubica en la transición entre la intuición investigativa y la construcción de un modelo estructural evaluable. Existen manuales y artículos especializados que explican criterios técnicos de SEM y PLS-SEM, tales como confiabilidad, validez, *bootstrapping*, predicción, comparación de modelos o reporte de resultados; sin embargo, muchos investigadores requieren una ruta más progresiva, que muestre cómo pasar de una idea amplia a un modelo estructural coherente. En ciencias de la administración, esta necesidad es especialmente importante porque los objetos de estudio —innovación, liderazgo, transformación digital, sostenibilidad, capacidades organizacionales, comportamiento del consumidor, desempeño, aprendizaje organizacional o adopción tecnológica— suelen ser constructos complejos, latentes, multidimensionales y dependientes del contexto. Por ello, este libro busca cubrir el espacio entre “tener un tema” y “construir un modelo estructural defendible”.

Objetivo del libro. El objetivo general de esta obra es desarrollar una ruta metodológica aplicada para que el lector pueda **construir, justificar, evaluar, interpretar y comunicar modelos estructurales en ciencias de la administración**, con énfasis en la lógica SEM/PLS-SEM. El libro no se limita a explicar índices ni procedimientos técnicos; su propósito es formar criterio investigador. Esto implica mostrar cómo una idea se convierte en fenómeno investigable; cómo el fenómeno se transforma en problema estructural; cómo la pregunta organiza relaciones entre constructos; cómo los conceptos se traducen en variables, constructos, dimensiones e indicadores; cómo la teoría permite formular hipótesis; cómo se evalúa el modelo de medición; cómo se interpreta el modelo estructural; y cómo los resultados se reportan, discuten y convierten en un producto académico.

Metodología empleada en el libro. La metodología de esta obra es de carácter **conceptual-metodológico**. Se parte de la revisión, integración y organización de literatura especializada sobre construcción de teoría, formulación de problemas, desarrollo de constructos, modelos de medición, SEM, PLS-SEM, evaluación

estructural, predicción, robustez, comparación de modelos y reporte académico. A partir de esa base, se propone una secuencia aplicada orientada a la práctica investigativa: primero se delimita el objeto conceptual; después se organiza el sistema de relaciones; posteriormente se definen constructos e indicadores; más adelante se evalúan medición y estructura; finalmente se interpretan resultados, se discuten contribuciones y se presenta el modelo como producto científico. En este sentido, la metodología del libro no consiste en un ejercicio puramente abstracto, sino en una ruta de decisión para ayudar al investigador a responder preguntas concretas: **qué estudiar, cómo delimitarlo, cómo formularlo, cómo medirlo, cómo modelarlo, cómo evaluarlo y cómo comunicarlo académicamente.**

Para facilitar la lectura, el libro se organiza como una ruta progresiva. Cada capítulo cumple una función específica dentro del tránsito que va desde una idea inicial hasta un modelo estructural evaluado y convertido en producto académico. El lector no encontrará una secuencia fragmentada de conceptos, sino un recorrido acumulativo: cada capítulo prepara el siguiente y evita que PLS-SEM sea entendido como una simple operación de software.

El **Capítulo 1, "La idea antes del modelo"**, introduce la base del razonamiento estructural. Su propósito es mostrar que toda investigación puede iniciar con una idea, pero que dicha idea todavía no constituye un fenómeno investigable. El capítulo guía al lector en el paso de una inquietud amplia a una realidad delimitada, situada y susceptible de medición. También explica cómo distinguir tema, fenómeno, problema y modelo; cómo formular una pregunta estructural; cómo diferenciar conceptos, variables y constructos; y cómo valorar la viabilidad conceptual, empírica y metodológica del estudio. Este capítulo invita al lector a comprender que SEM no inicia en el software, sino en la capacidad de construir una arquitectura conceptual previa.

El **Capítulo 2, "Sistema conceptual y lógica del modelo"**, profundiza en la transformación del problema en una estructura conceptual organizada. El capítulo muestra que un problema de investigación no es una simple descripción de la realidad, sino una tensión investigable: algo no suficientemente explicado, medido, relacionado, contextualizado o aplicado. A partir de esta lógica, se explican los tipos de vacío —teórico, empírico, metodológico y práctico—, la distinción entre explicación y predicción, la identificación de antecedentes, consecuencias y mecanismos, y la construcción del sistema conceptual preliminar antes del modelo SEM. Este capítulo ayuda al lector a reconocer que el problema de investigación es la matriz desde la cual se derivan variables, relaciones, hipótesis e indicadores.

El **Capítulo 3, "De la teoría a las variables"**, desarrolla el tránsito desde el sistema conceptual hacia una red de relaciones estructurales. Aquí se explica cómo la teoría permite justificar direcciones, funciones y vínculos entre constructos. El capítulo aborda la variable dependiente como eje organizador del modelo, las variables explicativas como antecedentes, los mediadores como mecanismos, los moderadores como condiciones y las hipótesis como expresiones evaluables de las relaciones teóricas. También presenta un panorama de las técnicas SEM y ubica a PLS-SEM y CB-SEM

dentro de una familia metodológica más amplia. Su contribución central es mostrar que cada flecha del modelo debe ser una afirmación teórica defendible, no una posibilidad gráfica generada por el software.

El **Capítulo 4, "Del concepto al constructo medible"**, se concentra en la operacionalización. Su función es explicar cómo los conceptos abstractos se convierten en variables, constructos, dimensiones, indicadores e ítems. Se enfatiza la necesidad de definir el dominio conceptual de cada constructo, distinguir entre variables observables y constructos latentes, revisar la dimensionalidad, desarrollar escalas iniciales y especificar conceptualmente la medición antes de aplicar criterios estadísticos. Este capítulo es crucial porque la interpretación estructural solo será válida si los constructos fueron definidos y medidos con rigor. En otras palabras, no puede haber un buen modelo estructural si antes no existe una buena arquitectura de medición.

El **Capítulo 5, "PLS-SEM, del constructo al indicador"**, introduce la evaluación técnica del modelo de medición. El capítulo explica cómo especificar constructos reflectivos, formativos, compuestos y jerárquicos; cómo valorar confiabilidad y validez convergente en constructos reflectivos; cómo evaluar validez discriminante; cómo revisar colinealidad, sesgo de método común y calidad de indicadores; y cómo considerar tamaño de muestra, potencia estadística y viabilidad del modelo. Su aportación consiste en mostrar que los criterios de medición no deben aplicarse mecánicamente, sino interpretarse según la naturaleza del constructo, la lógica de los indicadores, la teoría de base y el propósito del estudio.

El **Capítulo 6, "Robustez, mediación, moderación, MICOM, MGA y reporte"**, se ocupa de la evaluación avanzada del modelo estructural. En este capítulo se revisa la robustez y estabilidad de las relaciones entre constructos; se explican mediación, moderación y efectos complejos; se introduce la invariancia de medición y el análisis multigrupo mediante MICOM y MGA; se aborda la evaluación del poder predictivo del modelo; y se desarrolla la comparación de modelos. La idea central es que un modelo SEM/PLS-SEM no termina cuando se obtienen coeficientes significativos, sino cuando esos resultados se interpretan con prudencia, se robustecen, se comparan y se reportan de manera transparente. Este capítulo ayuda al lector a pasar de la estimación básica a una lectura metodológicamente defendible del modelo.

El **Capítulo 7, "Del modelo SEM al producto de investigación"**, integra todo el proceso y muestra cómo convertir el modelo evaluado en una tesis, artículo, capítulo de libro o informe académico. El capítulo explica cómo cerrar la ruta desde la idea hasta el modelo evaluado; cómo construir el modelo SEM como producto científico; cómo redactar el apartado metodológico; cómo presentar e interpretar resultados SEM/PLS-SEM; y cómo desarrollar discusión, contribuciones, limitaciones y futuras líneas de investigación. Este cierre muestra que el verdadero dominio de SEM/PLS-SEM no consiste solo en ejecutar un modelo, sino en construirlo, justificarlo, evaluarlo, interpretarlo y comunicarlo como conocimiento científico.

La lógica general de la obra se sintetiza en la siguiente tabla de ruta metodológica, que funciona como mapa conceptual de lectura.

Tabla. Ruta metodológica del libro

Etapa	Capítulo	Pregunta orientadora	Función metodológica	Resultado esperado
Delimitación inicial	**1**	¿Cómo convertir una idea amplia en un fenómeno investigable?	Ordena la idea, el fenómeno, el problema inicial, la pregunta estructural y la viabilidad del estudio.	Fenómeno delimitado, pregunta preliminar y condiciones mínimas de investigación.
Sistema conceptual	**2**	¿Qué vacío de conocimiento justifica el estudio?	Identifica vacíos teóricos, empíricos, metodológicos o prácticos, y organiza antecedentes, consecuencias y mecanismos.	Sistema conceptual preliminar y lógica general del modelo.
Relaciones teóricas	**3**	¿Cómo se traducen la teoría y el problema en variables e hipótesis?	Define variable dependiente, variables explicativas, relaciones estructurales, hipótesis y enfoque SEM/PLS-SEM.	Modelo relacional preliminar con hipótesis justificadas.
Construcción de constructos	**4**	¿Cómo convertir conceptos en constructos medibles?	Delimita conceptos, constructos, dimensiones, indicadores, ítems y especificación conceptual antes de medir.	Constructos definidos, indicadores alineados y escala inicial defendible.
Evaluación de medición	**5**	¿Cómo valorar la calidad de constructos e indicadores en PLS-SEM?	Evalúa especificación reflectiva, formativa, compuesta o jerárquica; confiabilidad, validez, colinealidad, sesgo de método común, muestra y potencia.	Modelo de medición técnicamente defendible.
Evaluación estructural avanzada	**6**	¿Cómo interpretar, robustecer, predecir y comparar modelos PLS-SEM?	Integra robustez estructural, mediación, moderación, MICOM, MGA, poder predictivo y comparación de modelos.	Modelo estructural evaluado, robusto, interpretable y comparativamente defendible.
Producto académico	**7**	¿Cómo convertir el modelo evaluado en tesis, artículo o informe?	Organiza metodología, resultados, interpretación, discusión, contribuciones, limitaciones y futuras líneas de investigación.	Producto académico completo, coherente y comunicable.

En conjunto, esta ruta invita al lector a comprender que SEM/PLS-SEM no comienza con la estimación del modelo, sino con la construcción rigurosa de una pregunta investigable, una arquitectura conceptual coherente y una medición defendible. Cada capítulo prepara el siguiente y permite avanzar de manera ordenada desde la idea inicial hasta la comunicación académica de los resultados. Así, el libro propone una lectura progresiva para quienes buscan transformar una inquietud de investigación en un modelo estructural sólido, interpretable y útil para las ciencias de la administración.

CAPÍTULO 1. La idea antes del modelo

Todo proceso de investigación estructural suele comenzar con una idea, aunque dicha idea, por sí sola, todavía no constituye un fenómeno investigable. **En este libro, SEM se entiende como una familia de enfoques de modelado estructural y no como una técnica única. Por ello, antes de elegir entre CB-SEM, PLS-SEM, PLSc, GSCA, *path* analysis u otros enfoques relacionados, el investigador debe construir una arquitectura conceptual previa: idea, fenómeno, problema, pregunta, propósito, conceptos, variables, constructos e indicadores.** En las ciencias de la administración, las inquietudes iniciales pueden surgir alrededor de la **innovación**, el **liderazgo**, la **transformación digital**, la **sostenibilidad**, las **capacidades organizacionales**, el **comportamiento del consumidor** o el **desempeño empresarial**. No obstante, estas nociones requieren ser **delimitadas conceptualmente** para convertirse en **objetos de análisis**. En este sentido, el punto de partida no consiste únicamente en elegir un tema atractivo, sino en transformar una preocupación amplia en una **arquitectura conceptual inicial** que permita sostener, de manera progresiva, **variables, constructos, indicadores e hipótesis** (Mejía-Trejo, 2023).

Esta transición exige que el investigador pase del **interés general** a una **realidad delimitada, situada y susceptible de medición**. Para ello, resulta necesario distinguir entre **tema, fenómeno, problema y modelo**, ya que el análisis estructural no opera sobre intuiciones amplias, sino sobre **relaciones organizadas entre variables observables y constructos latentes**. Antes de seleccionar un enfoque SEM, un software o un procedimiento de estimación, el investigador debe identificar con claridad la unidad de análisis, el contexto empírico, la variable central del estudio y las posibles relaciones explicativas que darán forma al modelo conceptual inicial (Gefen et al., 2000).

Una vez delimitado el fenómeno, el siguiente avance consiste en convertirlo en un **problema de investigación**. Un fenómeno puede ser observable, relevante e incluso pertinente para la administración, pero solo adquiere estatus de **problema científico** cuando revela una tensión específica: un **vacío teórico**, una **insuficiencia empírica**, una **limitación metodológica** o una **necesidad práctica no resuelta**. Por ello, formular el problema implica evitar planteamientos genéricos y construir una **base argumentativa** capaz de derivar **variables, hipótesis, relaciones esperadas y criterios de medición** coherentes con un modelo estructural (Hair et al., 2021).

A partir de esta problematización, la investigación debe avanzar hacia una **pregunta estructural**. A diferencia de una pregunta meramente descriptiva, la pregunta estructural expresa **relaciones entre constructos** y permite anticipar **efectos directos, mediaciones, moderaciones o vínculos explicativos más complejos**. Su formulación obliga, además, a precisar si el estudio busca **explicar, predecir o combinar ambos propósitos**, ya que esta decisión incide directamente en la **lógica de construcción, estimación y evaluación del modelo** (Shmueli, 2010).

El **propósito investigativo** también orienta la elección del **tipo de modelo SEM**. No es lo mismo desarrollar un estudio **confirmatorio**, **explicativo**, **predictivo** o centrado en la **validación de la medición**, pues cada finalidad demanda supuestos, técnicas y criterios de evaluación distintos. En consecuencia, la elección entre **CB-SEM, PLS-SEM, PLSc, GSCA o *path* analysis** debe responder a la coherencia entre **teoría, pregunta de investigación, naturaleza de los constructos, tipo de indicadores, características de los datos y propósito metodológico del estudio** (Hair et al., 2021).

Antes de estimar cualquier modelo, el investigador debe asegurar ciertas **condiciones mínimas**. Entre ellas se encuentran la **delimitación contextual**, la **definición de la variable dependiente**, la **selección de variables explicativas**, la **especificación de constructos reflectivos o formativos**, la **calidad preliminar de los indicadores**, la **validez conceptual**, la posible **colinealidad**, el **sesgo de método común**, el **tamaño de muestra** y la **potencia estadística**. Estas condiciones permiten comprender que el análisis estructural debe ser **consecuencia lógica del diseño**

conceptual, y no una operación mecánica derivada del uso del software (Gefen et al., 2000).

En conjunto, esta ruta permite comprender que **SEM no inicia con el software ni con la estimación estadística, sino con** la capacidad del investigador para formular un fenómeno investigable, construir un problema claro, plantear una pregunta estructural y definir un propósito metodológico coherente. Antes de evaluar confiabilidad, validez, ajuste, capacidad explicativa, capacidad predictiva o significancia de las relaciones, es indispensable aprender a pensar el modelo como un sistema conceptual defendible, articulado y metodológicamente consistente (Mejía-Trejo, 2023).

De la idea al fenómeno investigable

Toda investigación estructural inicia con una idea, pero esta todavía no constituye un fenómeno investigable. En ciencias de la administración, las ideas pueden surgir de problemas organizacionales, cambios tecnológicos, tensiones de mercado, innovación emergente, desempeño empresarial, transformación digital, sostenibilidad, liderazgo o comportamiento del consumidor. Sin embargo, mientras la idea permanezca como inquietud general, no permite definir variables, construir hipótesis ni seleccionar una técnica SEM. Decir “quiero estudiar innovación”, “me interesa la transformación digital” o “deseo analizar el liderazgo” expresa una orientación inicial, pero todavía no delimita qué se observará, en quiénes, bajo qué contexto, con qué propósito y mediante qué indicadores. **Por ello, el primer trabajo metodológico consiste en transformar la idea en un fenómeno concreto, situado, medible y conceptualmente defendible**. Esta conversión implica pasar del interés amplio a una formulación que permita identificar una unidad de análisis, un contexto de estudio, una variable central y posibles relaciones explicativas. En otras palabras, la idea adquiere valor científico cuando deja de ser intuición y se convierte en una ruta investigable. **Esta lógica es coherente con la necesidad de articular la idea, el planteamiento del problema, el marco teórico, la medición y la validación de constructos como fases conectadas de la investigación cuantitativa** (Mejía-Trejo, 2023).

El primer ajuste consiste en diferenciar tema, fenómeno, problema y modelo. El tema es el campo general de interés; el fenómeno es una manifestación específica de ese campo; el problema expresa una tensión investigable, y el modelo organiza variables, constructos e hipótesis para estudiar dicha tensión. Por ejemplo, “liderazgo” es un tema; “liderazgo transformacional en equipos virtuales” es un fenómeno; “la dificultad para explicar el desempeño colaborativo en equipos virtuales a pesar de altos niveles de liderazgo percibido” puede constituir un problema; y la relación entre liderazgo, confianza, aprendizaje y desempeño puede convertirse en un modelo estructural. Esta secuencia evita que el investigador avance prematuramente hacia el software sin haber definido el objeto conceptual de su estudio. Las técnicas SEM no operan sobre intereses generales, sino sobre relaciones entre **constructos latentes**

y variables observables previamente organizadas. Por ello, el fenómeno investigable debe contener cierta estructura: una realidad delimitada, una variable central, posibles antecedentes y una justificación teórica mínima. Si esta diferenciación no se realiza, el modelo puede transformarse en una acumulación de variables atractivas, pero sin arquitectura conceptual. El análisis estructural exige claridad previa porque integra medición y relaciones en un mismo sistema analítico (Gefen et al., 2000).

La transformación de la idea en fenómeno investigable exige comprender que SEM no debe asumirse como una técnica única, sino como una familia de enfoques orientados a representar fenómenos complejos mediante relaciones entre variables observables, constructos latentes, modelos de medición y modelos estructurales. En ciencias de la administración, muchos objetos de estudio no son observables de manera directa: confianza, innovación, compromiso, orientación emprendedora, capacidades dinámicas, aprendizaje organizacional o intención de adopción tecnológica. Estos conceptos requieren ser traducidos en **constructos**, y los constructos requieren ser representados mediante **indicadores**. Por ello, la idea debe formularse pensando desde el inicio en su posible medición. Si el investigador desea estudiar “capacidades digitales”, debe preguntarse qué dimensiones las componen, qué indicadores podrían observarlas y si se comportan como constructo reflectivo, formativo o compuesto. La calidad del modelo dependerá de esta traducción conceptual. Un software puede estimar parámetros, relaciones, criterios de medición o indicadores de ajuste y calidad del modelo, pero no puede definir por sí mismo si un constructo fue conceptualmente bien construido. En consecuencia, la idea debe madurar hasta convertirse en un sistema preliminar de constructos y relaciones. Solo así podrá decidirse si el análisis posterior será más adecuado mediante **CB-SEM, PLS-SEM, PLSc, GSCA o *path* analysis** (Hair et al., 2021).

Un fenómeno investigable debe expresar con claridad si el estudio busca **explicar**, **predecir** o combinar ambos propósitos. Esta decisión es fundamental porque no todos los modelos persiguen la misma finalidad. Un modelo explicativo intenta comprender por qué ocurre un fenómeno y cómo se justifican teóricamente las relaciones entre variables. Un modelo predictivo busca anticipar resultados con precisión empírica. En administración, esta distinción es crítica porque muchos estudios declaran explicar causalmente un fenómeno, pero utilizan criterios orientados a predicción; otros reportan alta varianza explicada, pero no ofrecen una contribución teórica clara. Desde la idea inicial, el investigador debe establecer qué tipo de conocimiento desea generar. Si busca confirmar teoría, deberá justificar relaciones con mayor rigor conceptual. Si busca predecir desempeño, adopción, satisfacción o innovación, deberá cuidar la capacidad predictiva del modelo. Esta decisión también influirá en la técnica SEM seleccionada, en el tamaño de muestra, en la evaluación del modelo y en el tipo de reporte final. Por tanto, convertir la idea en fenómeno investigable implica definir el propósito analítico antes de recolectar datos o ejecutar software. La confusión entre **explicación** y **predicción** debilita la coherencia metodológica del estudio (Shmueli, 2010).

El fenómeno investigable requiere una **delimitación conceptual** que indique qué se incluirá y qué quedará fuera del estudio. Delimitar no significa reducir la importancia de la investigación; significa hacerla científicamente manejable. Una idea como "inteligencia artificial en empresas" puede derivar en múltiples fenómenos: adopción de IA, confianza en sistemas inteligentes, productividad asistida por IA, capacidades analíticas, automatización de procesos, toma de decisiones algorítmica o innovación basada en datos. Cada ruta genera variables, indicadores e hipótesis diferentes. Si el investigador no delimita, corre el riesgo de mezclar niveles, conceptos y relaciones incompatibles. Un fenómeno bien delimitado debe responder: **qué ocurre**, **dónde ocurre**, **a quién afecta**, **por qué importa** y **qué relación podría analizarse**. Esta delimitación permite construir preguntas más claras, revisar literatura pertinente y evitar modelos sobrecargados. Además, prepara el camino para distinguir entre variables independientes, dependientes, mediadoras y moderadoras. En términos estructurales, la delimitación es el primer filtro de coherencia. Un modelo no debe intentar explicarlo todo; debe explicar aquello que fue definido como fenómeno central de investigación. La claridad conceptual inicial mejora la calidad posterior de la medición y de las relaciones propuestas (Mejía-Trejo, 2023).

La idea también debe vincularse con una **unidad de análisis**. Esta decisión establece quién o qué será observado: individuos, equipos, empresas, instituciones, proyectos, regiones, cadenas de suministro o ecosistemas. La unidad de análisis no es un detalle administrativo, sino una condición lógica del modelo. Si el estudio formula hipótesis sobre organizaciones, los datos deben representar atributos organizacionales; si estudia individuos, las variables deben interpretarse a nivel individual. Un error frecuente consiste en afirmar que se estudia "la empresa", pero recolectar respuestas individuales sin justificar cómo esas percepciones representan a la organización. Otro error es mezclar niveles: por ejemplo, relacionar actitudes individuales, capacidades organizacionales y competitividad sectorial sin explicar su integración. Esta confusión puede afectar la validez del modelo y la interpretación de resultados. En SEM, cada constructo debe corresponder al nivel empírico donde fue medido. Por ello, desde la idea inicial se debe responder: **¿cuál es la unidad de análisis?, ¿quién responderá?, ¿qué representa cada respuesta?, ¿a qué nivel se interpretarán los resultados?**. La unidad de análisis actúa como frontera metodológica del fenómeno investigable y evita extrapolaciones indebidas (Gefen et al., 2000).

El **contexto** también forma parte del fenómeno investigable. En ciencias de la administración, las relaciones entre variables rara vez son universales de manera absoluta. Una relación entre liderazgo y desempeño puede variar entre pymes, corporaciones, universidades, startups, instituciones públicas o empresas familiares. La adopción tecnológica puede depender del sector, país, madurez digital, presión competitiva, cultura organizacional o recursos disponibles. Por ello, el contexto no debe presentarse como un escenario decorativo, sino como un argumento de pertinencia. Investigar innovación en pymes mexicanas no equivale a estudiarla en multinacionales europeas; analizar transformación digital en servicios no es igual que hacerlo en manufactura. El contexto permite justificar por qué el fenómeno merece ser estudiado

ahí y no en otro espacio. Además, delimita el alcance de las conclusiones: un modelo no debe prometer generalizaciones más amplias de lo que permite su diseño. El investigador debe precisar **dónde ocurre el fenómeno**, **qué condiciones lo hacen relevante** y **qué límites impone a la interpretación**. Esta contextualización fortalece la originalidad del estudio y evita que el modelo parezca genérico o desconectado de la realidad administrativa (Mejía-Trejo, 2023).

Todo fenómeno investigable necesita una **variable central**. En modelos estructurales, esta variable suele representar el resultado que se desea explicar o predecir: desempeño organizacional, innovación, intención de adopción, satisfacción, lealtad, productividad, resiliencia, competitividad o sostenibilidad. La variable central actúa como eje del sistema conceptual porque permite ordenar las demás variables. Si no se sabe qué se desea explicar, no puede justificarse qué factores deben incluirse como antecedentes. Por ejemplo, si el fenómeno es “desempeño innovador de pymes ante la digitalización”, la variable central podría ser desempeño innovador; a partir de ella se justificarían capacidades digitales, aprendizaje organizacional, cultura innovadora o liderazgo tecnológico. Sin una variable dependiente clara, el modelo se vuelve una red sin dirección. Con una variable central bien definida, cada constructo puede ocupar una función: explicar, mediar, moderar o controlar. Esta claridad resulta indispensable para construir hipótesis coherentes y evitar relaciones forzadas. En términos metodológicos, la variable central permite convertir la idea en una pregunta estructural. El modelo no debe iniciar por todas las variables posibles, sino por aquello que se desea comprender como resultado principal (Hair et al., 2021).

Después de identificar la variable central, el investigador debe seleccionar **variables explicativas** con función teórica clara. Estas variables no deben elegirse por moda académica, facilidad de medición o simple disponibilidad de escalas. Deben incorporarse porque ayudan a explicar el fenómeno central. Cada variable explicativa debe responder una pregunta: **¿por qué este constructo podría influir en la variable dependiente?** Si no existe una razón conceptual convincente, su presencia debilita el modelo. Muchos modelos principiantes agregan múltiples antecedentes porque aparecen en estudios previos, pero sin una lógica integradora. Esto produce diagramas extensos, con muchas flechas y poca claridad. La arquitectura conceptual exige parsimonia: incluir solo las variables necesarias para responder la pregunta de investigación. Además, cada relación debe justificarse mediante teoría, evidencia previa o razonamiento lógico. En SEM, una flecha no es un adorno gráfico; representa una hipótesis que debe poder defenderse antes de estimarse. Por tanto, la selección de variables explicativas es una tarea de pensamiento teórico, no de acumulación bibliográfica. La calidad del modelo depende menos del número de constructos y más de la coherencia entre problema, variables e hipótesis (Gefen et al., 2000).

En algunos casos, el fenómeno investigable requiere **mediadores** o **moderadores**. Una variable mediadora explica el mecanismo mediante el cual una variable independiente influye en una dependiente. Por ejemplo, las capacidades digitales podrían afectar el desempeño innovador a través del aprendizaje organizacional. En ese caso, el aprendizaje explica cómo ocurre el efecto. Una variable moderadora, en

cambio, indica bajo qué condiciones una relación cambia en intensidad o dirección. Por ejemplo, la turbulencia ambiental podría fortalecer o debilitar la relación entre capacidades digitales e innovación. La mediación responde al **cómo** o **por qué**; la moderación responde al **cuándo**, **para quién** o **bajo qué condiciones**. Esta diferencia es esencial para evitar modelos confusos. Incluir mediadores y moderadores solo para aumentar complejidad suele producir modelos difíciles de defender. La complejidad únicamente aporta valor cuando mejora la comprensión del fenómeno. Por ello, desde la idea inicial debe decidirse si el modelo necesita relaciones directas, indirectas, condicionadas o una combinación de ellas. Un modelo más complejo no es necesariamente más científico; lo será solo si cada relación adicional tiene una función conceptual clara. La arquitectura conceptual debe crecer por necesidad explicativa, no por ornamentación estadística (Hair et al., 2021).

La idea debe evaluarse también por su **potencial de medición**. Los modelos SEM trabajan con variables observables y constructos latentes; por tanto, el fenómeno debe poder traducirse en indicadores. Conceptos como confianza, innovación, compromiso, capacidades dinámicas o aprendizaje organizacional no se observan directamente. Se representan mediante escalas, ítems, dimensiones o indicadores objetivos. Si el investigador no puede explicar cómo observará empíricamente el fenómeno, la idea todavía no está lista para convertirse en modelo. Esto no significa que todos los indicadores estén definidos desde el primer momento, pero sí que exista una ruta plausible de operacionalización. Deben anticiparse preguntas como: **¿el constructo puede medirse?, ¿existen escalas previas?, ¿los indicadores serán reflectivos, formativos o compuestos?, ¿la población puede responderlos?, ¿los datos serán accesibles?**. La medición no es un trámite técnico posterior; forma parte de la viabilidad conceptual. Un fenómeno puede ser relevante, pero si no puede representarse empíricamente, no será adecuado para análisis estructural cuantitativo. Por ello, transformar una idea en fenómeno investigable implica anticipar cómo esa realidad será convertida en datos válidos y confiables (Mejía-Trejo, 2023).

La transformación de la idea en fenómeno investigable debe evitar el **coleccionismo de variables**. Este problema aparece cuando el investigador incorpora constructos porque son populares, porque los encontró en la literatura o porque parecen interesantes, pero sin una función clara dentro del modelo. El resultado suele ser un diagrama sobrecargado, con baja coherencia teórica, posible colinealidad y difícil interpretación. Un modelo sólido no requiere todas las variables posibles, sino las variables necesarias. La parsimonia es una condición de calidad: un modelo con pocos constructos bien articulados puede ser más fuerte que uno con muchas relaciones débiles. Cada variable debe cumplir una función específica: explicar, ser explicada, mediar, moderar o controlar. Si no cumple ninguna, debe excluirse. Esta decisión exige disciplina intelectual, porque implica renunciar a elementos atractivos pero innecesarios. En análisis estructural, más complejidad no garantiza más contribución. De hecho, la complejidad injustificada puede aumentar exigencias de muestra, reducir potencia estadística y dificultar la defensa del modelo. Por ello, desde la idea inicial, el investigador debe construir modelos suficientes, no modelos

saturados. La calidad se encuentra en la coherencia, no en la cantidad (Hair et al., 2021).

El fenómeno investigable debe reconocer el **alcance** del estudio. Una idea puede derivar en investigación exploratoria, descriptiva, correlacional, explicativa o predictiva. No todos los alcances justifican las mismas técnicas ni las mismas inferencias. Si el objetivo es explorar dimensiones, puede requerirse análisis factorial exploratorio; si se busca confirmar una estructura de medición, puede ser pertinente el análisis factorial confirmatorio; si se desean evaluar relaciones entre constructos latentes, SEM resulta adecuado; si se busca explicación-predicción en modelos complejos, puede ser pertinente. Esta definición evita prometer más de lo que el diseño puede sostener. Por ejemplo, un estudio transversal con datos perceptuales puede analizar relaciones teóricamente justificadas, pero debe ser prudente al afirmar causalidad fuerte. El alcance no se decide por aspiración, sino por coherencia entre problema, teoría, datos, medición y técnica analítica. Desde la idea, el investigador debe preguntarse qué tipo de evidencia desea producir y qué tan fuerte puede ser su inferencia. Esta claridad protege la integridad científica del estudio y evita interpretaciones exageradas de los resultados (Mejía-Trejo, 2023).

Otro elemento clave es la **viabilidad metodológica**. Una idea puede ser atractiva, novedosa y relevante, pero inviable si no existen datos accesibles, si la población es difícil de alcanzar, si el instrumento resulta demasiado extenso, si la muestra probable será insuficiente o si los constructos son difíciles de medir. La viabilidad debe revisarse desde el inicio, no cuando el modelo ya está diseñado. En modelos estructurales, la complejidad tiene consecuencias: más constructos implican más indicadores; más relaciones exigen mayor estabilidad estadística; más mediaciones o moderaciones requieren mayor cuidado en potencia estadística. Además, la calidad de los datos dependerá de la claridad de los ítems, del acceso a informantes y de la consistencia del diseño. Por ello, el fenómeno investigable debe ser ambicioso, pero posible. La pregunta metodológica básica es: **¿puedo recolectar datos suficientes y adecuados para responder lo que deseo investigar?** Si la respuesta es negativa, la idea debe ajustarse. Ajustar el alcance no reduce valor; aumenta rigor. La viabilidad es una condición de calidad porque conecta la arquitectura conceptual con la posibilidad real de análisis empírico (Hair et al., 2021).

Pasar de la idea al fenómeno investigable implica anticipar los **criterios mínimos de calidad** que serán evaluados en el análisis posterior. Si el constructo está mal definido, el AVE difícilmente resolverá el problema; si los indicadores son redundantes, el VIF puede evidenciarlo; si dos constructos son conceptualmente indistinguibles, el HTMT puede mostrar falta de validez discriminante; si el modelo tiene demasiadas relaciones para una muestra limitada, la potencia estadística será insuficiente. Por tanto, los criterios de confiabilidad, validez, ajuste, colinealidad, capacidad explicativa, capacidad predictiva, tamaño de muestra y potencia estadística no son simples resultados finales; son consecuencias de cómo se pensó la idea desde el inicio. Esta es la tesis central del capítulo: antes de correr un modelo, hay que aprender a construirlo. El verdadero inicio del análisis estructural no ocurre al importar una base

de datos, sino cuando una idea general se transforma en un fenómeno delimitado, medible y defendible **(**Shmueli, 2010).

Del fenómeno al problema estructural

Un **fenómeno investigable** todavía no es, por sí mismo, un **problema de investigación**. El fenómeno indica qué parte de la realidad administrativa será observada; el problema, en cambio, expresa la **tensión científica** que justifica estudiarla. Por ejemplo, “transformación digital en pymes” es un fenómeno; pero “la falta de claridad sobre cómo las capacidades digitales se relacionan con el desempeño innovador en pymes” ya se acerca a un problema. Esta distinción es fundamental porque muchos estudios se quedan en la descripción del fenómeno sin explicar qué vacío, contradicción o necesidad de conocimiento buscan atender. Un problema de investigación debe mostrar **qué no se sabe**, **qué no se ha explicado suficientemente**, **qué relación permanece débilmente probada** o **qué contexto requiere evidencia específica**. En las ciencias de la administración, el problema puede surgir de la práctica, pero debe formularse científicamente. La baja productividad, la resistencia al cambio o la débil innovación pueden motivar el estudio; sin embargo, el problema académico aparece cuando esas situaciones se conectan con variables, teoría, medición y posibilidad de contraste empírico. Por ello, el tránsito del fenómeno al problema exige ordenar la observación inicial, revisar antecedentes, identificar vacíos y formular una necesidad de explicación clara, pertinente y medible (Mejía-Trejo, 2023).

El **problema de investigación** debe estar construido de tal manera que pueda conducir a un **modelo estructural**. Esto significa que no basta con declarar una situación general; es necesario formular una relación posible entre conceptos, variables o constructos. Las técnicas SEM permiten analizar simultáneamente modelos de medición y modelos estructurales, pero requieren que el problema esté expresado en términos de relaciones defendibles. Si el problema se formula como “las empresas tienen bajo desempeño”, todavía falta definir qué factores podrían explicar ese desempeño. En cambio, si se plantea que “no se comprende suficientemente cómo la orientación al mercado y las capacidades digitales explican el desempeño innovador”, el problema ya contiene una lógica estructural. Esta lógica permite identificar variables antecedentes, variable dependiente y posibles rutas de relación. Además, facilita distinguir si el estudio requerirá análisis de relaciones directas, mediadas o moderadas. Un problema mal planteado obliga a improvisar el modelo; un problema bien planteado orienta el diagrama estructural desde el inicio. Por ello, el problema debe escribirse pensando en su posterior traducción a hipótesis, indicadores y análisis SEM (Gefen et al., 2000).

El problema también debe definir si el estudio se orientará hacia **confirmación**, **explicación** o **predicción**. Esta decisión no debe posponerse hasta el análisis de resultados, porque afecta la forma de construir el problema desde el principio. Si el problema surge de una teoría consolidada que se desea contrastar, el estudio tendrá un énfasis confirmatorio. Si surge de la necesidad de comprender relaciones entre

constructos en un contexto específico, tendrá un énfasis explicativo. Si surge de la necesidad de anticipar resultados organizacionales, como desempeño, adopción o satisfacción, tendrá un énfasis predictivo. En la familia SEM, esta distinción es especialmente relevante porque algunos enfoques privilegian la confirmación teórica y el ajuste global, mientras otros se orientan con mayor énfasis a la explicación, la predicción o la estimación basada en componentes. Sin embargo, aun cuando el estudio use SEM, el problema debe expresar con claridad qué se desea conocer. No debe confundirse una alta varianza explicada con una explicación teórica sólida, ni un modelo predictivo con una prueba causal definitiva. Por eso, al formular el problema, el investigador debe declarar si pretende **validar teoría**, **explicar relaciones** o **predecir un resultado administrativo** (Hair et al., 2021).

El problema de investigación se fortalece cuando distingue entre **explicar** y **predecir**. En administración, muchas investigaciones utilizan estas palabras como si fueran equivalentes, pero no lo son. Explicar implica responder por qué ocurre un fenómeno, qué mecanismos lo producen y cómo se justifican teóricamente las relaciones entre variables. Predecir implica anticipar resultados con base en patrones empíricos y capacidad de generalización hacia casos nuevos. Esta diferencia afecta la redacción del problema. Si el problema dice “no se conoce qué factores predicen la intención de adopción tecnológica”, el énfasis será distinto a decir “no se comprende por qué la confianza influye en la intención de adopción tecnológica”. El primer planteamiento conduce a una lógica predictiva; el segundo, a una lógica explicativa. Ambos son legítimos, pero requieren criterios distintos para evaluar el modelo. El problema, por tanto, debe anticipar el tipo de conocimiento que se desea producir (Shmueli, 2010).

Un problema sólido debe identificar un **vacío de conocimiento**. El vacío no debe inventarse ni declararse de manera genérica; debe derivarse de la relación entre fenómeno, literatura y contexto. Existen distintos tipos de vacío. Puede haber un **vacío teórico** cuando una relación no ha sido explicada suficientemente; un **vacío empírico** cuando existen pocos estudios en un contexto específico; un **vacío metodológico** cuando las formas de medición son insuficientes; o un **vacío práctico** cuando un problema organizacional relevante carece de explicación aplicable. Por ejemplo, afirmar que “hay pocos estudios sobre transformación digital” es débil si no se especifica en qué campo, población o relación. En cambio, señalar que “la literatura ha analizado la transformación digital, pero aún no explica suficientemente su relación con el desempeño innovador en pymes de economías emergentes” ofrece una ruta más clara. El vacío debe ser preciso porque de él dependerán la pregunta, los objetivos y las hipótesis. Un vacío mal formulado produce un problema débil; un vacío claro justifica la necesidad del estudio y orienta la arquitectura conceptual (Mejía-Trejo, 2023).

El problema debe contener una **variable resultado** o, al menos, una consecuencia administrativa relevante. Esta variable resultado será posteriormente la base de la variable dependiente del modelo. Sin ella, el problema pierde dirección. Por ejemplo, si el fenómeno es “liderazgo en equipos virtuales”, el problema puede enfocarse en

desempeño colaborativo, compromiso, aprendizaje, innovación o satisfacción. Cada elección produce un modelo diferente. Por eso, el investigador debe decidir qué resultado desea comprender. En modelos SEM, esta variable resultado permite organizar el sistema: algunas variables serán antecedentes, otras mecanismos intermedios y otras condiciones que modifican relaciones. Un problema sin variable resultado suele generar diagramas dispersos, donde todas las variables parecen relacionarse con todas, pero ninguna ocupa un lugar central. En cambio, cuando el problema declara con claridad qué resultado será explicado o predicho, el modelo adquiere dirección. Esta decisión también permite evaluar la pertinencia de los indicadores, la muestra y la técnica de análisis. La formulación del problema debe responder: **¿qué fenómeno final importa?, ¿por qué importa?, ¿qué variables podrían explicarlo y qué valor tendría comprenderlo?** (Hair et al., 2021).

El problema de investigación también debe justificar la **pertinencia contextual**. En ciencias de la administración, el contexto no es solo el lugar donde se recolectan datos; es parte de la explicación. Una relación entre variables puede variar según sector, tamaño de empresa, país, cultura organizacional, nivel tecnológico o madurez institucional. Por ello, el problema debe indicar por qué ese contexto es relevante. No basta con decir “se estudiarán pymes” o “se analizarán empresas de servicios”; debe explicarse qué hace que ese contexto sea significativo para el fenómeno. Por ejemplo, las pymes pueden tener recursos limitados, estructuras flexibles, menor formalización o mayor vulnerabilidad ante cambios tecnológicos. Estas características pueden modificar la forma en que las capacidades digitales influyen en la innovación. Así, el contexto ayuda a construir el problema, no solo a describir la muestra. También delimita el alcance de las conclusiones: los resultados no deben generalizarse más allá de las condiciones estudiadas. Un problema bien contextualizado mejora la contribución del estudio porque muestra dónde, por qué y para quién importa investigar esa relación (Mejía-Trejo, 2023).

La formulación del problema debe evitar la **ambigüedad conceptual**. Una redacción ambigua produce variables ambiguas, hipótesis ambiguas e indicadores ambiguos. Por ejemplo, decir “se estudiará el impacto de la tecnología en las empresas” es demasiado general. ¿Qué tecnología? ¿Qué tipo de impacto? ¿En qué empresas? ¿Impacto sobre productividad, innovación, satisfacción, ventas o aprendizaje? En cambio, “se analizará cómo las capacidades digitales se relacionan con el desempeño innovador en pymes manufactureras” delimita mejor el problema. La precisión conceptual es indispensable porque SEM exige definir constructos y relaciones antes del análisis. Si el problema usa conceptos demasiado amplios, después será difícil distinguir constructos, seleccionar indicadores y justificar relaciones. Además, la ambigüedad puede generar problemas de validez discriminante, porque constructos mal diferenciados tienden a solaparse. Por ello, el problema debe redactarse con palabras específicas, medibles y coherentes con la literatura. Cada término central del problema debe poder convertirse en una definición conceptual y, posteriormente, en un conjunto de indicadores. El problema bien escrito ya anticipa la calidad del modelo (Gefen et al., 2000).

Un problema de investigación debe ser **viable**. La viabilidad no significa limitar la ambición intelectual, sino asegurar que el estudio pueda realizarse con rigor. Para evaluar viabilidad, el investigador debe preguntarse si tendrá acceso a la población, si podrá recolectar datos suficientes, si existen escalas o indicadores adecuados, si el modelo no será excesivamente complejo y si el tiempo disponible permite ejecutar el diseño. En SEM, la viabilidad es especialmente importante porque el número de constructos, indicadores y relaciones afecta la muestra requerida y la estabilidad del modelo. Un problema puede ser interesante, pero inviable si exige datos longitudinales que no se podrán obtener, informantes inaccesibles o mediciones demasiado especializadas. Ajustar el problema no reduce su calidad; puede aumentar su precisión. Por ejemplo, en lugar de estudiar "todas las capacidades organizacionales que influyen en la competitividad empresarial", puede delimitarse a "capacidades digitales y aprendizaje organizacional como antecedentes del desempeño innovador en pymes". Esta versión es más manejable y modelable. Un problema viable permite avanzar hacia un diseño empírico realista, sin perder pertinencia científica (Hair et al., 2021).

El problema debe formularse con una **estructura lógica de relación**. Esto significa que debe señalar, explícita o implícitamente, cómo se conectan los elementos centrales del fenómeno. En investigación estructural, las relaciones pueden ser directas, indirectas, mediadas o moderadas. Un problema puede plantear que no se comprende suficientemente el efecto directo de una variable sobre otra, el mecanismo mediante el cual ocurre ese efecto o las condiciones bajo las cuales se fortalece o debilita. Por ejemplo, un problema directo sería: "no se conoce suficientemente la relación entre capacidades digitales y desempeño innovador". Un problema mediado sería: "no se comprende si el aprendizaje organizacional explica el vínculo entre capacidades digitales y desempeño innovador". Un problema moderado sería: "no se sabe si la turbulencia ambiental modifica la relación entre capacidades digitales e innovación". Esta estructura lógica permite que el problema se convierta después en hipótesis. Sin ella, el modelo aparece desconectado del planteamiento. El problema debe anticipar las rutas del modelo, pero sin convertir todavía el texto en un reporte técnico (Gefen et al., 2000).

La redacción del problema debe conservar una relación equilibrada entre **realidad práctica** y **fundamento académico**. En administración, muchos problemas surgen de situaciones reales: empresas que no innovan, empleados que no adoptan tecnología, clientes que pierden confianza o instituciones que no logran mejorar desempeño. Sin embargo, el libro debe enseñar al investigador que una situación práctica necesita traducirse a lenguaje científico. No basta con afirmar que existe una dificultad; hay que indicar qué relación conceptual permitirá estudiarla. Por ejemplo, la baja innovación puede analizarse mediante capacidades, cultura, aprendizaje, liderazgo o recursos. La elección depende de la teoría y del vacío identificado. Esta traducción evita que la investigación se convierta en diagnóstico empresarial sin aporte académico. Al mismo tiempo, impide que el estudio sea puramente teórico y desconectado de la práctica. El problema ideal articula ambos planos: muestra una necesidad real y una oportunidad científica. Así, el estudio puede contribuir tanto a la literatura como a la toma de

decisiones en organizaciones. Esta doble pertinencia fortalece el valor del modelo (Mejía-Trejo, 2023).

El problema debe orientar la **pregunta de investigación**. Una pregunta no debe aparecer como frase aislada, sino como consecuencia natural del planteamiento. Si el problema señala que no se comprende cómo las capacidades digitales influyen en el desempeño innovador, la pregunta podría formularse así: "¿en qué medida las capacidades digitales se relacionan con el desempeño innovador de las pymes?" Si además se sospecha un mecanismo, podría ampliarse: "¿qué papel mediador desempeña el aprendizaje organizacional en esta relación?" La pregunta debe conservar coherencia con el problema, porque de ella derivarán objetivos, hipótesis, variables e indicadores. Una mala práctica consiste en redactar un problema, una pregunta y un objetivo que no coinciden entre sí. Esa incoherencia se arrastra hasta el modelo. Por ello, el problema debe funcionar como matriz de decisiones. Todo lo posterior debe responder a él. Si una variable no aparece justificada por el problema, debe revisarse. Si una hipótesis no ayuda a responder la pregunta, debe eliminarse. Esta consistencia permite construir modelos más parsimoniosos y defendibles (Hair et al., 2021).

Un buen problema también debe anticipar el **tipo de técnica SEM** que podría utilizarse más adelante. No se trata de elegir software en esta etapa, sino de reconocer qué tipo de problema se está formulando. Si el problema busca confirmar un modelo teórico consolidado y evaluar ajuste global, podría orientarse hacia CB-SEM. Si busca explicar o predecir resultados en modelos complejos, PLS-SEM puede ser pertinente. Si se trabaja con variables observadas sin constructos latentes, quizá un *path* analysis sea suficiente. Si el problema se centra en medición, puede requerir primero EFA o CFA. Esta anticipación metodológica evita que el investigador fuerce cualquier problema dentro de una técnica específica. La selección técnica debe responder al propósito, al tipo de constructo, al grado de teoría, a la muestra y a la naturaleza de la medición (Gefen et al., 2000).

El problema debe incorporar una reflexión inicial sobre **muestra y potencia estadística**, aunque el cálculo detallado se realice después. Si el problema propone un modelo muy complejo con múltiples constructos, mediadores y moderadores, necesitará una muestra suficiente para estimar relaciones con estabilidad. Si la población es pequeña o difícil de acceder, el problema debe ajustarse para evitar un modelo sobredimensionado. Esto es especialmente importante para los investigadores, quienes suelen diseñar modelos ambiciosos sin considerar si podrán recolectar datos adecuados. Sin embargo, desde el planteamiento debe existir conciencia de que la calidad del modelo no depende solo de la teoría, sino también de la suficiencia de datos. Un problema viable debe equilibrar relevancia, complejidad y posibilidad empírica. El tamaño de muestra y la potencia no son detalles finales; son condiciones que deben anticiparse desde el diseño (Hair et al., 2021).

El problema de investigación debe evitar promesas causales excesivas. En ciencias de la administración, muchos estudios usan lenguaje causal sin contar con diseños que permitan sostener causalidad fuerte. SEM puede evaluar relaciones estructurales

teóricamente justificadas, pero la fuerza causal depende del diseño, temporalidad, medición, control de sesgos y calidad de la evidencia. Por ello, el problema debe redactarse con prudencia. En lugar de afirmar de inicio “la variable X causa Y”, puede formularse como “se analiza la relación estructural entre X y Y” o “se examina el efecto teóricamente esperado de X sobre Y”. Esta precisión protege la integridad metodológica. La causalidad requiere más que coeficientes significativos; requiere argumentación conceptual, diseño adecuado y control de explicaciones alternativas. En modelos transversales basados en encuestas, conviene ser especialmente cuidadoso. El problema puede proponer relaciones direccionales, pero debe reconocer sus límites. Esta prudencia no debilita el estudio; lo vuelve más riguroso. Una investigación sólida no exagera lo que puede demostrar **(**Shmueli, 2010).

El paso del fenómeno al problema de investigación debe cerrar con una **formulación sintética y defendible**. Un buen problema puede expresarse en pocas líneas, pero detrás de esas líneas debe existir delimitación, vacío, contexto, variable central, propósito y viabilidad. Una estructura útil sería: “Aunque la literatura ha estudiado [fenómeno general], aún no se comprende suficientemente [relación o vacío específico] en [contexto/unidad de análisis], lo cual limita [explicación, predicción o aplicación]. Por ello, este estudio analiza [relación central] mediante [enfoque conceptual]”. Esta formulación ayuda al investigador a pasar de ideas amplias a problemas modelables. En síntesis, el problema es el puente entre fenómeno y modelo. Si está bien formulado, orienta variables, hipótesis, medición, muestra y técnica. Si está mal formulado, todo el análisis posterior queda comprometido. Por eso, antes de estimar cualquier modelo estructural, el investigador debe aprender a escribir un problema claro, pertinente, viable y estructuralmente analizable **(**Mejía-Trejo, 2023).

De la pregunta a la relación estructural

El paso del **problema de investigación** a la **pregunta estructural** es decisivo porque convierte una tensión científica en una orientación analítica concreta. El problema explica qué no se sabe, qué relación está insuficientemente comprendida o qué vacío requiere atención; la pregunta, en cambio, formula con precisión qué se buscará responder. En estudios orientados a SEM, la pregunta no debe limitarse a describir un fenómeno, sino que debe expresar una posible relación entre variables, constructos o dimensiones. Por ejemplo, un problema puede señalar que no se comprende suficientemente el papel de las capacidades digitales en el desempeño innovador de las pymes. La pregunta estructural derivada podría ser: **¿en qué medida las capacidades digitales se relacionan con el desempeño innovador de las pymes?** Esta pregunta ya permite identificar una variable explicativa, una variable resultado y una unidad de análisis. Si además se sospecha un mecanismo, puede formularse una pregunta mediada: **¿qué papel desempeña el aprendizaje organizacional en la relación entre capacidades digitales y desempeño innovador?** La pregunta estructural debe ser clara, medible y coherente con el problema. No es una frase decorativa; es el eje que conectará objetivos, hipótesis, constructos, indicadores y técnica de análisis (Mejía-Trejo, 2023).

Una **pregunta estructural** se distingue de una pregunta general porque contiene una lógica de relación. Preguntas como "¿qué es la innovación?", "¿cuáles son las características del liderazgo?" o "¿cómo se define la transformación digital?" pueden ser útiles para revisiones conceptuales, estudios exploratorios o capítulos teóricos, pero no son suficientes para construir un modelo SEM. En cambio, preguntas como "¿cómo influyen las capacidades digitales en la innovación organizacional?", "¿en qué medida la confianza explica la intención de adopción tecnológica?" o "¿qué efecto tiene el liderazgo transformacional sobre el aprendizaje organizacional?" ya contienen relaciones susceptibles de modelarse. Esta diferencia es importante porque SEM trabaja con sistemas de relaciones entre constructos latentes y variables observadas. La pregunta debe anticipar, aunque sea de forma preliminar, la arquitectura del modelo. Una buena pregunta estructural permite reconocer qué variable será explicada, qué variables actuarán como antecedentes y qué relaciones merecen evaluación. Si la pregunta no contiene estructura, el modelo será improvisado. Por ello, antes de definir hipótesis o seleccionar indicadores, el investigador debe revisar si su pregunta realmente puede convertirse en un sistema estructural analizable (Gefen et al., 2000).

La pregunta estructural debe estar alineada con el **tipo de modelo SEM** que posiblemente se utilizará. Si la pregunta busca confirmar una estructura teórica ya consolidada, puede orientar hacia un enfoque más confirmatorio. Si busca explicar o predecir una variable dependiente en un modelo complejo, puede ser compatible con PLS-SEM. Si solo relaciona variables observadas, quizá no requiere un modelo de variables latentes y podría resolverse mediante *path* analysis. Esta correspondencia evita que el investigador formule preguntas que después no se ajustan a la técnica seleccionada. Por ejemplo, una pregunta centrada en la validación de una escala requiere énfasis en el modelo de medición; una pregunta centrada en efectos entre constructos exige modelo estructural; una pregunta sobre predicción debe considerar capacidad predictiva. Por ello, la pregunta no debe formularse de manera aislada, sino pensando en su traducción posterior a constructos, indicadores y relaciones (Hair et al., 2021).

La pregunta estructural debe diferenciar entre **explicar** y **predecir**, porque ambas finalidades conducen a formulaciones distintas. Una pregunta explicativa busca comprender por qué ocurre una relación entre variables: **¿cómo influye la confianza en la intención de adopción tecnológica?** o **¿por qué el aprendizaje organizacional fortalece el desempeño innovador?** En cambio, una pregunta predictiva busca anticipar un resultado: **¿qué factores predicen mejor la intención de adopción tecnológica?** o **¿qué combinación de capacidades permite anticipar el desempeño innovador?** La diferencia no es solo semántica; afecta la selección de variables, la evaluación del modelo y la interpretación de resultados. Una pregunta explicativa requiere teoría fuerte, hipótesis justificadas y claridad causal conceptual. Una pregunta predictiva requiere valorar capacidad de anticipación, precisión y utilidad empírica. En administración, muchos estudios combinan ambas finalidades, pero deben declararlo con cuidado. Si una pregunta dice "explicar y predecir", el modelo debe evaluarse con criterios coherentes para ambas metas. Esta distinción protege al

investigador de confundir una alta varianza explicada con una explicación teórica suficiente, o una relación significativa con verdadera capacidad predictiva (Shmueli, 2010).

Una pregunta estructural debe contener una **variable dependiente explícita** o claramente inferible. La variable dependiente representa el fenómeno que se desea explicar o predecir; por ello, debe aparecer en el centro de la formulación. Preguntas como "¿qué factores influyen en la innovación?" son útiles, pero pueden ser todavía amplias si no se define qué tipo de innovación se estudiará. Sería más preciso preguntar: **¿en qué medida las capacidades digitales y el aprendizaje organizacional explican el desempeño innovador de las pymes manufactureras?** En esta versión, el resultado central es desempeño innovador, las variables explicativas son capacidades digitales y aprendizaje organizacional, y el contexto son pymes manufactureras. Esta claridad permite construir objetivos, hipótesis e indicadores. Sin variable dependiente clara, el modelo se vuelve difuso y puede terminar con múltiples resultados sin jerarquía. La pregunta debe funcionar como brújula del modelo: todo constructo incluido debe ayudar a responderla. Si una variable no se conecta con la pregunta, probablemente no pertenece al sistema estructural. Por ello, formular la pregunta exige decidir qué resultado administrativo tiene prioridad científica (Mejía-Trejo, 2023).

La pregunta estructural también debe precisar las **variables explicativas**. No basta con preguntar "qué factores influyen", porque esta expresión puede abrir un campo ilimitado de posibilidades. Una buena pregunta identifica constructos específicos o, al menos, familias conceptuales justificadas. Por ejemplo, "¿cómo influyen las capacidades digitales en el desempeño innovador?" es más modelable que "¿qué influye en la innovación?". Si se desea incorporar varias variables, deben tener una función clara. Una pregunta como **¿en qué medida las capacidades digitales, la cultura innovadora y el aprendizaje organizacional explican el desempeño innovador?** ya ofrece una estructura más definida. Sin embargo, la pregunta no debe saturarse de variables. Si se incluyen demasiados constructos desde la pregunta, el modelo puede perder parsimonia. El reto consiste en equilibrar precisión y claridad. La pregunta debe ser suficientemente específica para orientar el modelo, pero no tan extensa que se convierta en una lista de variables sin jerarquía. En SEM, cada variable explicativa debe justificar una flecha potencial. Por tanto, la pregunta estructural debe anticipar relaciones defendibles, no solo enumerar conceptos interesantes (Gefen et al., 2000).

Cuando el problema sugiere mecanismos intermedios, la pregunta debe formular una posible **mediación**. Una pregunta de mediación no solo pregunta si X influye en Y, sino si esa influencia ocurre a través de M. Por ejemplo: **¿el aprendizaje organizacional media la relación entre capacidades digitales y desempeño innovador?** Esta formulación es más precisa porque introduce un mecanismo explicativo. La mediación es útil cuando el investigador no solo quiere saber si existe una relación, sino cómo ocurre. En ciencias de la administración, muchas relaciones necesitan mecanismos: el liderazgo puede influir en desempeño a través de

motivación; la digitalización puede influir en innovación a través de aprendizaje; la cultura organizacional puede influir en satisfacción a través de compromiso. La pregunta mediada exige teoría, porque no se debe incluir un mediador únicamente para sofisticar el modelo. Debe existir una razón conceptual para pensar que la variable intermedia transmite el efecto. Además, la pregunta de mediación anticipa decisiones analíticas posteriores, como efectos indirectos, intervalos de confianza y tamaño del efecto (Hair et al., 2021).

Cuando el problema sugiere condiciones o diferencias contextuales, la pregunta puede formular una **moderación**. Una pregunta de moderación no se centra en el mecanismo, sino en cuándo o bajo qué condiciones cambia una relación. Por ejemplo: **¿la turbulencia ambiental modera la relación entre capacidades digitales y desempeño innovador?** En este caso, la pregunta supone que el efecto de las capacidades digitales puede ser más fuerte o más débil dependiendo del nivel de turbulencia. Esta estructura es útil en administración porque muchas relaciones no operan igual en todos los contextos. La cultura organizacional, el tamaño de empresa, la experiencia del usuario, la presión competitiva o el apoyo directivo pueden modificar relaciones estructurales. La pregunta moderadora debe ser clara: debe indicar la relación principal y la variable que altera su intensidad o dirección. No debe confundirse con mediación. La mediación explica el **cómo**; la moderación explica el **cuándo** o **en qué condiciones**. Esta precisión conceptual evita errores posteriores en el diseño del modelo. Una pregunta de moderación bien formulada prepara al investigador para entender interacciones, análisis multigrupo y comparación de efectos (Gefen et al., 2000).

La pregunta estructural debe ser coherente con el **nivel de medición**. Si se pregunta por relaciones entre percepciones individuales, los indicadores deberán recolectarse a nivel individual. Si se pregunta por capacidades organizacionales, debe justificarse cómo se medirán esas capacidades: mediante directivos, datos secundarios, agregación de respuestas o indicadores objetivos. Esta coherencia es fundamental porque una pregunta puede parecer correcta, pero ser metodológicamente problemática si mezcla niveles. Por ejemplo, preguntar “¿cómo influye el liderazgo del director en la competitividad regional?” requiere explicar cómo una variable individual u organizacional se conecta con un resultado regional. En SEM, la pregunta debe respetar la unidad de análisis y el tipo de datos. Además, debe anticipar si los constructos serán reflectivos, formativos o compuestos. Una pregunta sobre “factores que forman la capacidad digital” no es igual a una pregunta sobre “manifestaciones de la capacidad digital”. La primera puede orientar a modelos formativos o compuestos; la segunda a modelos reflectivos. Por ello, la pregunta estructural debe redactarse pensando en la naturaleza de la medición futura (Hair et al., 2021).

La pregunta debe ser **viable empíricamente**. Una pregunta puede ser intelectualmente atractiva, pero inviable si exige datos inaccesibles, muestra demasiado grande, mediciones difíciles o diseños longitudinales imposibles. Por ejemplo, preguntar “¿cómo evoluciona durante diez años la relación entre

transformación digital y competitividad internacional?" puede ser relevante, pero no viable para un investigador con tiempo y recursos limitados. En cambio, una pregunta como "¿en qué medida las capacidades digitales se relacionan con el desempeño innovador percibido en pymes de servicios?" puede ser más manejable. La viabilidad no reduce la calidad del estudio; ayuda a construir una investigación posible. En modelos SEM, la viabilidad también depende del número de constructos, indicadores e hipótesis. Una pregunta demasiado amplia puede llevar a un modelo sobredimensionado y con baja potencia estadística. Por ello, la pregunta estructural debe equilibrar ambición y factibilidad. Debe ser suficientemente relevante para aportar conocimiento, pero suficientemente delimitada para poder responderse con datos adecuados. Esta revisión evita que el modelo fracase por exceso de complejidad (Mejía-Trejo, 2023).

Una buena pregunta estructural debe mantener **parsimonia**. La parsimonia significa formular una pregunta clara, directa y enfocada, sin incorporar más elementos de los necesarios. Por ejemplo, una pregunta como "¿en qué medida las capacidades digitales, la cultura innovadora, el liderazgo transformacional, el aprendizaje organizacional, la orientación al mercado, la resiliencia estratégica y la turbulencia ambiental explican el desempeño innovador?" puede ser demasiado pesada para un primer modelo. Aunque cada variable pueda ser interesante, la pregunta pierde claridad. Una versión más parsimoniosa podría centrarse en tres elementos: **¿en qué medida las capacidades digitales influyen en el desempeño innovador a través del aprendizaje organizacional?** Esta pregunta ya contiene variable explicativa, mediador y resultado. La parsimonia permite que el modelo sea más fácil de defender, medir, estimar e interpretar. También favorece el aprendizaje de investigadores principiantes, quienes necesitan comprender primero la lógica estructural antes de trabajar modelos más complejos. Una pregunta parsimoniosa no es una pregunta simple; es una pregunta enfocada. En SEM, la claridad de la pregunta es más valiosa que la abundancia de variables (Gefen et al., 2000).

La pregunta estructural debe facilitar la formulación de **objetivos**. Si la pregunta está bien formulada, el objetivo general surge casi de manera natural. Por ejemplo, de la pregunta "¿en qué medida las capacidades digitales influyen en el desempeño innovador de las pymes?" puede derivarse el objetivo: **analizar la influencia de las capacidades digitales sobre el desempeño innovador de las pymes**. Si la pregunta incluye mediación, el objetivo puede incorporar el mecanismo: **evaluar el papel mediador del aprendizaje organizacional en la relación entre capacidades digitales y desempeño innovador**. Esta correspondencia evita incoherencias frecuentes entre pregunta, objetivo e hipótesis. Cuando la pregunta dice una cosa y el objetivo otra, el modelo pierde consistencia. Por eso, la pregunta debe funcionar como matriz del diseño. Todo lo posterior debe derivarse de ella: objetivos, hipótesis, variables, indicadores y análisis. Una pregunta bien escrita reduce errores posteriores (Mejía-Trejo, 2023).

La pregunta estructural también debe preparar la construcción de **hipótesis**. Una hipótesis es una respuesta tentativa a la pregunta, expresada como relación esperada

entre variables. Si la pregunta es "¿en qué medida las capacidades digitales influyen en el desempeño innovador?", la hipótesis podría ser: **las capacidades digitales influyen positiva y significativamente en el desempeño innovador**. Si la pregunta incluye mediación, la hipótesis puede indicar un efecto indirecto. Si incluye moderación, puede proponer que la relación cambia según cierta condición. Por ello, una pregunta mal formulada genera hipótesis débiles. La hipótesis no debe aparecer como frase aislada, sino como consecuencia lógica de la pregunta y del problema. Además, debe ser evaluable empíricamente. Preguntas vagas producen hipótesis vagas; preguntas precisas permiten hipótesis claras. En SEM, las hipótesis serán representadas como rutas, por lo que deben tener dirección y sentido. La pregunta estructural, entonces, es el puente entre el planteamiento del problema y el diagrama del modelo. Su función es ordenar la lógica de prueba que después se llevará al análisis (Hair et al., 2021).

La pregunta debe evitar **promesas causales excesivas**. En estudios transversales con encuestas, es común formular preguntas como "¿cuál es el impacto de X sobre Y?", pero el término impacto puede sugerir causalidad fuerte. Si el diseño no permite establecer temporalidad o control suficiente, conviene usar expresiones más prudentes, como **relación**, **influencia teóricamente esperada**, **efecto estructural estimado** o **asociación explicativa**. Esto no significa eliminar la dirección conceptual del modelo, sino reconocer los límites del diseño. SEM permite evaluar relaciones estructurales, pero no convierte automáticamente una encuesta transversal en experimento causal. Por ello, la pregunta debe ser metodológicamente responsable. Puede proponer relaciones direccionales sustentadas en teoría, pero debe evitar afirmaciones que excedan la evidencia posible. Esta prudencia fortalece el manuscrito porque muestra dominio metodológico. La pregunta estructural debe ser ambiciosa, pero científicamente honesta (Shmueli, 2010).

La pregunta estructural puede formularse en distintos niveles de complejidad. En un nivel básico, puede preguntar por una relación directa: **¿cómo influye X en Y?** En un nivel intermedio, puede incorporar mediación: **¿cómo influye X en Y a través de M?** En un nivel avanzado, puede incorporar moderación: **¿bajo qué condiciones X influye en Y?** También puede combinar ambas: **¿el efecto indirecto de X sobre Y a través de M cambia según Z?** Sin embargo, el nivel de complejidad debe corresponder al grado de madurez teórica, a la capacidad del investigador y a la disponibilidad de datos. Para principiantes, conviene iniciar con preguntas estructurales claras y progresivas. El objetivo no es formular la pregunta más sofisticada, sino la más coherente con el problema. Una pregunta compleja mal justificada puede ser más débil que una pregunta simple bien fundamentada. La complejidad debe agregarse cuando aporta explicación, no cuando solo embellece el modelo (Hair et al., 2021).

Finalmente, el paso del problema a la pregunta estructural debe cerrar con una formulación clara, directa y defendible. Una plantilla útil para los investigadores puede ser: **¿en qué medida [variable explicativa] influye/se relaciona con [variable dependiente] en [unidad de análisis/contexto]?** Si existe mediación: **¿qué papel**

mediador desempeña [M] en la relación entre [X] y [Y]? Si existe moderación: **¿en qué medida [Z] modifica la relación entre [X] y [Y]?** Estas estructuras ayudan a convertir problemas amplios en preguntas modelables. La pregunta estructural no es el modelo completo, pero sí su primera expresión lógica. Si está bien formulada, permitirá construir objetivos, hipótesis, constructos e indicadores con coherencia. Si está mal formulada, el modelo nacerá débil. Por ello, antes de hablar de AVE, VIF, HTMT, R^2 o *bootstrapping*, el investigador debe aprender a formular preguntas estructurales. El análisis estadístico empieza mucho antes del software: empieza cuando el investigador aprende a preguntar correctamente (Mejía-Trejo, 2023).

De los conceptos a las variables y constructos

El paso de los **conceptos** a las **variables** y **constructos** constituye una de las transiciones más delicadas en la investigación basada en SEM, porque define si una idea abstracta podrá convertirse en un modelo analizable, medible y defendible. Un concepto es una noción general que permite nombrar un fenómeno, como innovación, confianza, desempeño, aprendizaje organizacional o sostenibilidad. Sin embargo, mientras permanezca en ese nivel, todavía no puede incorporarse directamente a un modelo estructural. Para que tenga utilidad metodológica debe delimitarse, definirse y transformarse en una entidad susceptible de observación empírica. **El error frecuente consiste en asumir que nombrar un concepto equivale a construir una variable**, cuando en realidad el concepto solo abre una posibilidad de investigación. La variable requiere variación observable o medible; el constructo requiere definición teórica, dominio conceptual e indicadores. Por ejemplo, “innovación” puede ser un concepto amplio, pero en un modelo SEM debe precisarse si se estudiará como innovación de producto, proceso, modelo de negocio, capacidad innovadora o desempeño innovador. Cada decisión modifica el tipo de indicadores, la unidad de análisis, las relaciones esperadas y la interpretación de resultados. Por ello, antes de estimar un modelo, el investigador debe preguntarse qué significa exactamente cada concepto, qué parte del fenómeno representa y cómo será reconocido empíricamente. **La claridad conceptual es la condición previa para evitar modelos ambiguos, redundantes o estadísticamente válidos pero teóricamente débiles** (Churchill, 1979).

Una **variable** es una propiedad que puede variar entre personas, organizaciones, grupos, territorios o periodos. En ciencias de la administración, una variable puede representar percepciones, capacidades, prácticas, resultados, recursos, actitudes o comportamientos. Su función dentro del modelo es permitir que una idea teórica sea observada mediante diferencias empíricas. Por ejemplo, si todos los sujetos tuvieran exactamente el mismo nivel de compromiso, el compromiso no tendría variación útil para explicar otro resultado. En SEM, esta variación es indispensable porque el modelo analiza relaciones entre constructos medidos a partir de indicadores. Sin embargo, no toda variable es necesariamente un constructo latente. Algunas variables pueden ser observables directamente, como edad, antigüedad, número de empleados, ventas o años de experiencia. Otras variables son abstractas y requieren medición indirecta, como satisfacción, confianza, autoeficacia o cultura organizacional. **La diferencia**

central es que una variable observable se mide de forma directa, mientras que un constructo latente se infiere mediante indicadores. Esta distinción es importante porque define el tipo de modelo de medición. Si el investigador confunde variables observables con constructos latentes, puede diseñar instrumentos innecesariamente complejos o interpretar como constructo lo que en realidad es un dato directo. Por tanto, el tránsito de concepto a variable exige identificar si el fenómeno puede medirse de manera directa o si requiere una estructura de indicadores que represente una realidad no observable de forma inmediata (Hair et al., 2021).

El **constructo** es una entidad teórica que representa un fenómeno no observable directamente, pero inferible mediante manifestaciones empíricas. En SEM, los constructos son fundamentales porque permiten estudiar fenómenos complejos que no pueden medirse con una sola pregunta o dato. Por ejemplo, la confianza organizacional no se observa como un objeto físico; se infiere a partir de indicadores como percepción de honestidad, cumplimiento de promesas, competencia, benevolencia o seguridad en la relación. De igual manera, la orientación innovadora puede inferirse mediante prácticas, disposiciones, decisiones y comportamientos organizacionales. **El constructo no es el conjunto mecánico de ítems; es la idea teórica que los indicadores intentan representar**. Esta precisión evita un error común: creer que una escala crea automáticamente un constructo. En realidad, la escala solo mide si existe una definición conceptual previa suficientemente sólida. Si el constructo está mal definido, los índices estadísticos posteriores no solucionarán el problema. Un alfa aceptable, un AVE superior a .50 o cargas elevadas no garantizan que el constructo tenga sentido teórico. Por eso, la construcción del constructo debe iniciar con su dominio conceptual: qué incluye, qué excluye, cuáles son sus límites y cómo se diferencia de otros constructos próximos. Esta delimitación es especialmente importante cuando se trabaja con conceptos cercanos, como capacidades digitales, transformación digital, madurez digital e innovación tecnológica. **Sin delimitación conceptual, el modelo puede medir traslapes en lugar de relaciones reales** (Jarvis et al., 2003).

La transformación de un concepto en constructo exige definir su **dominio conceptual**. Este dominio representa el conjunto de significados legítimos que forman parte del constructo. Por ejemplo, si se define “desempeño innovador”, debe decidirse si incluye número de nuevos productos, mejora de procesos, resultados comerciales de la innovación, capacidad de adaptación o percepción de éxito innovador. Cada opción tiene consecuencias metodológicas. Si el dominio se define demasiado amplio, el constructo se vuelve confuso; si se define demasiado estrecho, puede perder riqueza explicativa. **Un buen dominio conceptual permite seleccionar indicadores pertinentes y excluir elementos que pertenecen a otros constructos**. Esta decisión evita mezclar antecedentes, componentes y consecuencias. Por ejemplo, la inversión en tecnología puede ser antecedente de innovación, pero no necesariamente parte del desempeño innovador. La cultura organizacional puede facilitar aprendizaje, pero no debe confundirse automáticamente con aprendizaje organizacional. Esta separación es crucial porque SEM analiza relaciones entre constructos; si los constructos contienen elementos de otros, las relaciones pueden inflarse artificialmente. Por ello,

el dominio conceptual no es un detalle de redacción, sino un criterio de validez. El investigador debe escribir una definición suficientemente precisa para que cualquier lector pueda entender qué se medirá y qué no se medirá. En términos prácticos, antes de construir ítems debe existir una matriz que vincule concepto, definición, dimensión, indicador y escala de respuesta. **La medición rigurosa comienza con fronteras conceptuales claras** (Churchill, 1979).

La distinción entre **constructos reflectivos, formativos y compuestos** debe anticiparse desde la etapa conceptual, no dejarse para el momento del análisis estadístico. Un constructo reflectivo supone que el fenómeno latente causa sus indicadores; si el constructo cambia, los indicadores deberían cambiar en la misma dirección. Por ejemplo, si aumenta la satisfacción, se espera que aumenten las respuestas positivas sobre agrado, cumplimiento de expectativas y evaluación general. En cambio, un constructo formativo se construye a partir de indicadores que representan componentes distintos; por ejemplo, el nivel socioeconómico puede formarse por ingreso, educación y ocupación. En este caso, eliminar un indicador puede cambiar el significado del constructo. Los constructos compuestos, frecuentes en SEM, integran indicadores como componentes de una entidad analítica construida. **La especificación incorrecta del tipo de constructo puede afectar toda la validez del modelo**. Si un constructo formativo se evalúa como reflectivo, se exigirán correlaciones internas que quizá no corresponden conceptualmente. Si un constructo reflectivo se trata como formativo, se puede perder la lógica de manifestación común. Por eso, el investigador debe preguntarse: ¿los indicadores reflejan el constructo o lo forman?, ¿son intercambiables?, ¿deben correlacionarse?, ¿su eliminación cambia el significado del constructo? Estas preguntas permiten prevenir errores antes de estimar el modelo. **La especificación conceptual correcta es más importante que aplicar mecánicamente índices estadísticos** (Diamantopoulos & Winklhofer, 2001).

La **dimensionalidad** es otro elemento clave en el paso de los conceptos a los constructos. Algunos constructos son unidimensionales porque representan una sola idea central; otros son multidimensionales porque integran varios componentes relacionados. Por ejemplo, la transformación digital puede incluir dimensiones tecnológicas, organizacionales, culturales y estratégicas. La sostenibilidad puede integrar dimensiones económica, social y ambiental. La capacidad de innovación puede incluir aprendizaje, recursos, procesos, colaboración y orientación al mercado. **La dimensionalidad permite representar constructos amplios sin convertirlos en conceptos vagos**. Sin embargo, la decisión de dividir un constructo en dimensiones debe justificarse teóricamente. No debe depender únicamente de un análisis factorial posterior ni de la conveniencia de agrupar ítems. Cuando un constructo se define como multidimensional, cada dimensión debe tener significado propio, indicadores pertinentes y relación clara con el constructo superior. Además, debe decidirse si las dimensiones se comportan como componentes formativos, manifestaciones reflectivas o subconstructos jerárquicos. Este punto es importante en SEM porque los modelos de orden superior pueden representar fenómenos complejos, pero también pueden introducir ambigüedad si no se justifican adecuadamente. Por ello, la dimensionalidad debe formularse antes de recolectar datos. El investigador debe explicar por qué el

constructo necesita dimensiones, qué aporta cada dimensión y cómo se integran conceptualmente. **Un constructo multidimensional no debe ser una colección de temas relacionados, sino una arquitectura coherente de significados** (Henseler, 2017).

El paso de constructo a indicadores requiere **operacionalización**, es decir, traducir una definición abstracta en manifestaciones observables. Esta traducción no debe hacerse de manera intuitiva ni improvisada. Cada indicador debe corresponder a una parte del dominio conceptual y debe redactarse de forma clara, específica y respondible para la unidad de análisis. Por ejemplo, si el constructo es "aprendizaje organizacional", no basta con preguntar si "la organización aprende"; deben formularse indicadores sobre adquisición, transferencia, interpretación y aplicación del conocimiento, siempre que esas dimensiones estén justificadas. **Un indicador adecuado no solo pregunta algo relacionado con el tema; representa empíricamente una parte del constructo**. Además, debe evitarse que los indicadores midan consecuencias o antecedentes. Si un ítem de aprendizaje organizacional pregunta por mejora del desempeño financiero, probablemente está midiendo resultado, no aprendizaje. Esta confusión debilita el modelo porque mezcla niveles conceptuales. También debe evitarse que los ítems sean dobles, ambiguos, excesivamente generales o cargados de juicio. En escalas Likert, cada afirmación debe permitir una respuesta graduada y comprensible. La operacionalización rigurosa requiere una tabla que muestre constructo, dimensión, indicador, redacción del ítem, escala y referencia de base. Esta matriz permite verificar trazabilidad y evitar que los indicadores se alejen del concepto original. **La calidad del modelo SEM depende en gran medida de la calidad de esta traducción conceptual-operativa** (Mejía-Trejo, 2023).

La relación entre **concepto, variable y constructo** también exige distinguir la función que cada elemento cumplirá dentro del modelo estructural. Un mismo constructo puede actuar como variable dependiente, independiente, mediadora, moderadora o de control, según la pregunta de investigación. Por ejemplo, la innovación puede ser resultado cuando se estudian sus antecedentes; puede ser mediadora cuando explica cómo las capacidades digitales influyen en el desempeño; y puede ser antecedente cuando se analiza su efecto sobre la competitividad. **La función de una variable no está dada por su nombre, sino por su posición lógica dentro del modelo**. Esta precisión es fundamental porque evita construir modelos en los que todas las variables parecen importantes, pero ninguna organiza realmente la explicación. La variable dependiente debe representar el resultado central que se desea explicar o predecir; las variables independientes deben funcionar como antecedentes justificados; las mediadoras deben explicar mecanismos; las moderadoras deben indicar condiciones; y las variables de control deben reducir explicaciones alternativas sin desplazar la lógica principal. Cuando esta arquitectura no se define, el modelo se convierte en una red dispersa de relaciones. Por ello, el investigador debe establecer desde el inicio qué constructo ocupa el lugar central, qué variables explican, qué variables transmiten efectos y cuáles delimitan condiciones. **La**

claridad funcional permite que el modelo sea parsimonioso, interpretable y coherente con el problema de investigación (Chin, 1998).

Además de variables dependientes e independientes, algunos modelos requieren **variables mediadoras o moderadoras** para representar procesos más complejos. Una variable mediadora explica el mecanismo mediante el cual una variable independiente se relaciona con una variable dependiente; por ejemplo, el aprendizaje organizacional puede mediar la relación entre capacidades digitales y desempeño innovador. Una variable moderadora, en cambio, indica bajo qué condiciones una relación cambia en intensidad o dirección; por ejemplo, la turbulencia ambiental puede fortalecer o debilitar la relación entre capacidades digitales e innovación. **La mediación responde al cómo o por qué ocurre una relación, mientras que la moderación responde al cuándo, para quién o bajo qué condiciones ocurre**. Esta diferencia es central para evitar modelos confusos. Si una variable se coloca como mediadora sin representar un proceso intermedio, el modelo pierde lógica causal. Si se coloca como moderadora sin justificar por qué alteraría la relación, se convierte en un recurso estadístico artificial. En SEM, cada efecto complejo debe derivarse de teoría y no de exploración oportunista. La mediación debe tener sentido temporal y conceptual: el antecedente influye en el mediador y el mediador influye en el resultado. La moderación debe justificar por qué la relación principal no opera igual en todos los contextos. **Un modelo con mediadores y moderadores bien definidos ofrece mayor profundidad explicativa sin sacrificar coherencia estructural** (Nitzl et al., 2016).

Cuando un constructo es amplio, puede requerir **dimensiones e indicadores**. Las dimensiones son componentes conceptuales que organizan internamente el constructo; los indicadores son manifestaciones observables que permiten medir cada dimensión o el constructo completo. Por ejemplo, la transformación digital puede incluir dimensiones tecnológicas, organizacionales, culturales y estratégicas; la innovación puede diferenciarse en innovación de producto, proceso, organización o mercadotecnia; y la sostenibilidad puede organizarse en dimensiones económica, social y ambiental. **Las dimensiones no son sinónimos decorativos del constructo, sino partes conceptualmente diferenciables que ayudan a representar su complejidad**. Esta distinción permite evitar dos errores: reducir constructos complejos a una sola pregunta o fragmentarlos en componentes sin lógica. Cada dimensión debe tener una función clara dentro del dominio conceptual y no debe confundirse con antecedentes o consecuencias. Por ejemplo, la capacitación puede ser antecedente de transformación digital, pero no necesariamente una dimensión de transformación digital, salvo que la definición del constructo la incluya explícitamente. Los indicadores, por su parte, deben ser redactados de manera observable, específica y alineada con la unidad de análisis. **Un constructo multidimensional exige una cadena de trazabilidad: concepto → definición → dimensiones → indicadores → ítems → escala**. Sin esa cadena, la medición puede parecer completa, pero carecer de fundamento conceptual (Jarvis et al., 2003).

La construcción de variables y constructos exige evitar la **redundancia conceptual**. En modelos SEM, es frecuente que el investigador incluya constructos con nombres distintos pero contenidos muy cercanos, como “orientación a la innovación”, “cultura innovadora”, “capacidad innovadora” y “comportamiento innovador”, sin aclarar sus diferencias. Esta práctica puede producir problemas de validez discriminante, colinealidad y sobreposición teórica. **Un modelo no mejora por acumular constructos similares; mejora cuando cada constructo cumple una función conceptual distinta**. Para evitar redundancia, el investigador debe comparar definiciones antes de diseñar indicadores. Si dos constructos comparten el mismo dominio conceptual, quizá deben fusionarse, redefinirse o ubicarse en niveles distintos. Por ejemplo, la cultura innovadora puede ser un antecedente del comportamiento innovador, mientras que el desempeño innovador puede ser una consecuencia. Si estos límites no se establecen, el modelo puede terminar midiendo la misma realidad con etiquetas diferentes. No obstante, el problema no nace en el software; nace en la conceptualización. Por eso, la depuración conceptual debe ocurrir antes de la estimación. **La validez discriminante empieza con definiciones diferenciadas, no con una tabla de resultados** (Henseler et al., 2015).

La selección de indicadores debe responder a la **unidad de análisis**. Un indicador no puede redactarse de la misma forma si la unidad de análisis es el individuo, el equipo, la organización, la institución o el territorio. Por ejemplo, “uso tecnologías digitales para mejorar mi trabajo” corresponde a nivel individual; “la empresa utiliza tecnologías digitales para mejorar sus procesos” corresponde a nivel organizacional. Si se mezclan niveles, el modelo pierde coherencia. **La unidad de análisis define quién responde, qué representa la respuesta y a qué nivel se interpretan las relaciones**. Esta precisión es esencial en ciencias de la administración, donde los estudios pueden trabajar con estudiantes, docentes, directivos, empresas, redes organizacionales o regiones. Si el constructo se define a nivel organizacional, pero los datos provienen de percepciones individuales, debe explicarse si el informante responde como representante de la organización o desde su experiencia personal. De lo contrario, las inferencias pueden ser incorrectas. Además, los indicadores deben usar lenguaje compatible con el nivel de análisis. No es igual medir “autoeficacia digital del estudiante” que “capacidad digital institucional”. Aunque ambos conceptos se relacionen con tecnología, pertenecen a niveles distintos. **Una buena operacionalización mantiene consistencia entre constructo, indicador, respondiente y nivel de interpretación** (Gefen et al., 2000).

Otro aspecto central es la **direccionalidad conceptual** entre variables. Para construir un modelo SEM, no basta con identificar constructos; es necesario definir cómo se relacionan y por qué una variable antecede a otra. La dirección de una relación debe derivarse de teoría, lógica temporal, evidencia previa o razonamiento sustantivo. Por ejemplo, puede ser razonable plantear que las capacidades digitales influyen en la innovación, pero también podría argumentarse que las organizaciones innovadoras desarrollan más capacidades digitales. La dirección elegida debe justificarse. **Una flecha en SEM no es un elemento gráfico; es una afirmación teórica sobre antecedente y consecuencia**. Si el modelo se estima con datos

transversales, la direccionalidad debe expresarse con prudencia, evitando afirmar causalidad fuerte sin diseño longitudinal o experimental. En este sentido, es preferible hablar de relación estructural esperada, influencia teóricamente sustentada o efecto compatible con la hipótesis. La direccionalidad también afecta la selección de mediadores y moderadores. Un mediador debe ubicarse conceptualmente después del antecedente y antes del resultado; un moderador debe representar una condición que modifica una relación. **La coherencia direccional evita modelos circulares, arbitrarios o imposibles de defender metodológicamente** (Shmueli, 2010).

El tránsito de conceptos a variables y constructos también exige cuidar la **parsimonia**. La parsimonia no significa construir modelos simples por obligación, sino incluir únicamente los constructos necesarios para responder la pregunta de investigación. Un modelo con demasiadas variables puede parecer sofisticado, pero volverse difícil de interpretar, exigir mayor muestra y generar problemas de colinealidad. **Más variables no equivalen a mayor explicación**. Cada constructo debe justificar su presencia mediante una función clara: explicar, ser explicado, mediar, moderar o controlar. Si una variable no cumple ninguna de estas funciones, probablemente debe excluirse. La parsimonia ayuda a evitar el coleccionismo conceptual, es decir, la tendencia a incorporar términos populares solo porque aparecen en la literatura reciente. Por ejemplo, agregar transformación digital, inteligencia artificial, sostenibilidad, resiliencia, innovación abierta y capacidades dinámicas en un solo modelo puede ser atractivo, pero no necesariamente coherente. El investigador debe priorizar la arquitectura del argumento: qué resultado quiere explicar, qué antecedentes son esenciales, qué mecanismo es relevante y qué condiciones modifican la relación. **Un modelo parsimonioso permite que cada constructo tenga peso teórico y que cada ruta sea interpretada con claridad** (Guenther et al., 2023).

La calidad de los constructos también depende de la **trazabilidad entre literatura, definición e instrumento**. Cada constructo debe estar respaldado por referencias que justifiquen su existencia, su definición, sus dimensiones y sus indicadores. Esto no significa copiar escalas sin reflexión, sino adaptar de manera fundamentada. En investigación SEM, una escala debe corresponder al contexto, a la unidad de análisis y al propósito del estudio. **La trazabilidad permite demostrar que los ítems no fueron inventados arbitrariamente**, sino derivados de un marco conceptual verificable. Una buena matriz de operacionalización debe mostrar el nombre del constructo, definición conceptual, dimensiones, indicadores, ítems, escala de respuesta y referencia de base. Este procedimiento facilita la revisión académica, mejora la transparencia y reduce errores de medición. También permite identificar vacíos: indicadores sin referencia, dimensiones sin definición o constructos sin relación clara con el problema. La trazabilidad es especialmente importante cuando se diseñan instrumentos nuevos, porque el investigador debe demostrar que cada ítem representa una parte legítima del constructo. **Sin trazabilidad, el modelo puede funcionar estadísticamente, pero quedar débil ante una evaluación metodológica rigurosa** (Mejía-Trejo, 2023).

El desarrollo de constructos debe anticipar su **evaluación posterior**. Aunque en esta etapa todavía no se calculen índices, el investigador debe saber que las decisiones conceptuales impactarán la confiabilidad, la validez convergente, la validez discriminante, la colinealidad y la capacidad predictiva. Por ejemplo, si los indicadores reflectivos no representan una misma idea, la confiabilidad será baja; si los constructos son demasiado parecidos, el HTMT puede ser alto; si los indicadores formativos se solapan, el VIF puede indicar colinealidad. **Los problemas estadísticos suelen ser síntomas de decisiones conceptuales previas**. Por ello, la construcción de variables y constructos debe hacerse pensando en la evaluación futura, pero sin subordinarse ciegamente a los índices. No se debe diseñar un constructo solo para obtener alfa alto; se debe diseñar para representar correctamente el fenómeno. La estadística debe validar una decisión conceptual, no reemplazarla. Este principio es central en SEM: los índices ayudan a diagnosticar, pero no crean teoría. **Un constructo bien diseñado tiene mayores probabilidades de mostrar consistencia empírica porque parte de una definición clara y de indicadores pertinentes** (Hair et al., 2019).

Pasar de los conceptos a las variables y constructos significa construir el **puente entre pensamiento teórico y evidencia empírica**. El concepto permite nombrar el fenómeno; la variable permite observar variación; el constructo permite representar una realidad abstracta; los indicadores permiten medirla; y el modelo permite analizar relaciones. Esta cadena debe mantenerse coherente desde la pregunta de investigación hasta el análisis SEM. **Cuando esta transición se realiza correctamente, el modelo deja de ser una acumulación de flechas y se convierte en una arquitectura conceptual medible**. En cambio, cuando se omite esta etapa, aparecen problemas posteriores: constructos ambiguos, indicadores débiles, hipótesis improvisadas, relaciones redundantes y resultados difíciles de defender. Por ello, el investigador debe dedicar tiempo a definir, delimitar, diferenciar y operacionalizar antes de estimar. En ciencias de la administración, donde muchos fenómenos son abstractos y multidimensionales, esta tarea es indispensable. Un buen modelo no nace en el software; nace en la precisión conceptual. **La fortaleza de un SEM depende de la calidad con que el investigador convierte ideas en variables, variables en constructos y constructos en indicadores observables** (Hair et al., 2021).

Viabilidad conceptual, empírica y metodológica del estudio

Antes de pasar al análisis estructural, el investigador debe verificar que su estudio cumple un conjunto de **condiciones mínimas conceptuales, metodológicas y técnicas**. Estas condiciones no sustituyen el análisis estadístico, pero preparan el terreno para que dicho análisis tenga sentido. En otras palabras, antes de estimar un modelo en SmartPLS, AMOS, EQS, LISREL o R, debe existir una arquitectura conceptual suficientemente clara. Esto implica haber delimitado la idea, formulado el fenómeno, construido el problema, redactado la pregunta estructural, definido el propósito investigativo y seleccionado variables coherentes. Si estas condiciones no están presentes, el software puede generar resultados numéricos, pero esos

resultados no necesariamente serán interpretables ni defendibles. El análisis estructural no debe entenderse como el inicio de la investigación, sino como una fase posterior a decisiones conceptuales previas. Sin esa secuencia, el modelo será una colección de variables, no un sistema de investigación (Mejía-Trejo, 2023).

Definir la unidad de análisis. El investigador debe saber si estudiará individuos, equipos, empresas, instituciones, proyectos, regiones, cadenas de suministro o ecosistemas. Esta decisión afecta todo el diseño: población, muestra, instrumento, indicadores e interpretación de resultados. Un error frecuente consiste en formular hipótesis organizacionales y medir percepciones individuales sin justificar la correspondencia entre niveles. Por ejemplo, si se afirma que "las capacidades organizacionales influyen en el desempeño empresarial", pero solo se encuesta a empleados sin criterio de agregación, puede existir una inconsistencia entre el nivel conceptual y el nivel empírico. De igual manera, si se estudian empresas, debe definirse quién responderá en nombre de la organización y por qué ese informante tiene conocimiento suficiente. La unidad de análisis es una frontera lógica: indica a qué nivel se interpretarán las relaciones del modelo. Antes del análisis estructural, el investigador debe responder: **¿quién o qué será observado?, ¿qué representa cada dato?, ¿el nivel de medición coincide con el nivel de las hipótesis?, ¿las conclusiones se harán sobre individuos, grupos u organizaciones?**. Si estas preguntas no están claras, el modelo puede producir inferencias equivocadas (Gefen et al., 2000).

Delimitación contextual. Todo modelo debe indicar dónde ocurre el fenómeno y bajo qué condiciones será estudiado. En ciencias de la administración, el contexto puede incluir sector económico, tamaño de empresa, país, región, tipo de organización, grado de digitalización, madurez institucional o condiciones de mercado. Esta delimitación no es secundaria, porque las relaciones entre variables pueden variar según el contexto. Por ejemplo, la relación entre capacidades digitales e innovación puede comportarse de forma distinta en pymes que en grandes corporaciones; la confianza puede tener efectos diferentes en comercio electrónico, educación virtual o servicios financieros; y la transformación digital puede depender de recursos, cultura y presión competitiva. Antes del análisis estructural, el investigador debe tener claro si el contexto fue elegido por conveniencia, por relevancia práctica o por vacío de literatura. También debe reconocer los límites de generalización. Un modelo construido en un contexto específico no debe presentarse como explicación universal. La delimitación contextual fortalece la defensa del estudio porque muestra por qué el fenómeno importa en ese escenario. Por ello, una condición mínima antes de modelar es responder: **¿dónde ocurre el fenómeno?, ¿por qué ese contexto es pertinente?, ¿qué límites impone a los resultados?** (Mejía-Trejo, 2023).

Definir con precisión la variable dependiente principal. Todo modelo estructural necesita un eje. Esa variable representa el resultado que se desea explicar o predecir: desempeño organizacional, innovación, satisfacción, intención de adopción, lealtad, productividad, resiliencia, competitividad o sostenibilidad. Sin variable dependiente clara, el modelo pierde dirección y se convierte en una red de relaciones sin jerarquía.

La variable dependiente debe derivarse del problema y de la pregunta estructural. Si el problema afirma que no se comprende suficientemente el desempeño innovador en pymes, entonces el desempeño innovador debe ocupar el lugar central del modelo. Las variables explicativas, mediadoras o moderadoras deberán organizarse alrededor de ese resultado. Antes del análisis estructural, el investigador debe preguntarse: **¿qué fenómeno final deseo explicar o predecir?, ¿por qué ese resultado es relevante?, ¿cómo se define conceptualmente?, ¿cómo se medirá?, ¿qué variables pueden antecederlo?**. Esta claridad permite construir hipótesis coherentes y seleccionar indicadores adecuados (Hair et al., 2021).

Justificar las variables explicativas. No toda variable interesante debe entrar al modelo. Una variable explicativa debe cumplir una función conceptual clara: ayudar a comprender, anticipar o condicionar la variable dependiente. Su inclusión debe responder a teoría, evidencia previa o argumentación lógica. Si el investigador incorpora variables solo porque son populares o porque existen escalas disponibles, el modelo se debilita. Antes del análisis estructural, cada variable explicativa debe responder: **¿por qué debe estar en el modelo?, ¿qué relación tiene con la variable dependiente?, ¿su efecto será directo, indirecto o condicionado?, ¿qué aporta que no aportan otras variables?**. Esta revisión evita redundancia conceptual y posibles problemas de colinealidad. También favorece la parsimonia, una condición clave para investigadores principiantes. Un modelo no debe ser grande para parecer sofisticado; debe ser coherente para ser defendible. Además, la justificación de variables explicativas prepara la interpretación futura de los coeficientes *path*. Si una relación no puede defenderse antes del análisis, difícilmente podrá interpretarse después, aunque resulte significativa. La selección de variables debe ser una decisión teórica, no una acumulación bibliográfica (Gefen et al., 2000).

Distinguir entre constructos reflectivos, formativos y compuestos. Esta decisión es indispensable porque afecta la forma de medir y evaluar el modelo. En un constructo reflectivo, los indicadores son manifestaciones del constructo; por ejemplo, varios ítems pueden reflejar satisfacción, confianza o compromiso. En un constructo formativo, los indicadores contribuyen a formar el constructo; por ejemplo, distintas capacidades pueden configurar una capacidad organizacional más amplia. En un constructo compuesto, los indicadores representan componentes que integran una entidad conceptual construida para un propósito analítico. Antes de usar SmartPLS, el investigador debe comprender que no todos los indicadores se evalúan igual. En modelos reflectivos se revisarán cargas externas, confiabilidad, AVE y validez discriminante. En modelos formativos o compuestos se revisarán pesos, significancia y colinealidad mediante VIF. Una mala especificación de la medición puede arruinar el modelo aunque los resultados parezcan aceptables. Por ello, antes del análisis estructural, el investigador debe responder: **¿qué tipo de constructo estoy midiendo?, ¿los indicadores reflejan o forman el constructo?, ¿la teoría justifica esa decisión?** (Hair et al., 2021).

Contar con indicadores preliminares adecuados. Los indicadores son la base empírica del constructo. Si están mal redactados, son ambiguos, redundantes o no

corresponden al concepto, el análisis posterior será débil. Antes del análisis estructural, el investigador debe revisar si cada indicador representa realmente el constructo, si la redacción es clara, si la escala de respuesta es adecuada y si la población podrá comprenderlo. También debe evitar ítems que mezclen dos ideas en una sola afirmación, preguntas con sesgo, términos excesivamente técnicos o indicadores que no correspondan al contexto. En esta etapa no se exige tener resultados estadísticos, pero sí una evaluación conceptual de la calidad del instrumento. Por ello, la condición mínima no es solo tener ítems, sino tener ítems coherentes con la definición conceptual del constructo. La medición empieza cuando se redacta el indicador (Mejía-Trejo, 2023).

Anticipar la validez convergente que se debe comprender desde ahora que la validez convergente evalúa si los indicadores de un constructo comparten suficiente varianza común. En PLS-SEM, uno de los criterios centrales será el **AVE**. Conceptualmente, esto significa que los indicadores deben representar el mismo constructo y no ideas dispersas. Si un constructo incluye indicadores demasiado heterogéneos, es probable que después tenga problemas de AVE o cargas externas. Por ejemplo, si se mide “transformación digital” mezclando infraestructura tecnológica, cultura digital, ventas en línea y habilidades individuales sin justificar dimensiones, el constructo puede volverse conceptualmente confuso. Antes del análisis, el investigador debe preguntarse: **¿mis indicadores realmente pertenecen al mismo constructo?, ¿representan una dimensión común?, ¿hay coherencia conceptual entre ellos?, ¿alguno parece medir otra cosa?**. Esta revisión previa evita depender únicamente de resultados numéricos. La validez convergente no es solo un índice; es una consecuencia de haber definido bien el constructo y sus indicadores (Hair et al., 2021).

Anticipar la validez discriminante. Esta permite evaluar si dos constructos son realmente distintos entre sí. Si dos constructos están definidos de manera muy parecida, si sus indicadores se solapan o si sus nombres son diferentes pero su contenido es casi idéntico, habrá riesgo de falta de validez discriminante. Por ejemplo, “capacidad digital”, “madurez digital” y “transformación digital” pueden confundirse si no se delimitan correctamente. Lo mismo ocurre con “satisfacción”, “confianza” y “lealtad” si no se distinguen teóricamente. Antes del análisis estructural, el investigador debe preguntarse: **¿cada constructo representa una idea diferente?, ¿sus indicadores son distinguibles?, ¿puedo explicar por qué no son lo mismo?, ¿la teoría respalda su separación?**. Esta revisión es esencial porque un modelo con constructos indistinguibles puede generar resultados estadísticamente problemáticos. La validez discriminante empieza en la definición conceptual, no en el cálculo del HTMT (Gefen et al., 2000).

Prever la colinealidad. En modelos estructurales, la colinealidad aparece cuando dos o más variables explicativas son demasiado similares o están altamente asociadas. Esto puede dificultar la interpretación de los efectos y debilitar la estabilidad del modelo.Si se incluyen constructos muy parecidos, antecedentes redundantes o indicadores formativos que capturan casi lo mismo, el modelo puede presentar

problemas. Por ejemplo, incluir simultáneamente “uso de tecnología”, “digitalización operativa” y “madurez digital” sin distinguirlos puede producir solapamientos. Antes del análisis estructural, el investigador debe preguntar: **¿mis variables explicativas son conceptualmente distintas?, ¿alguna repite el contenido de otra?, ¿los indicadores formativos son complementarios o redundantes?, ¿puedo justificar la presencia de cada variable?**. Prever colinealidad permite diseñar modelos más parsimoniosos y claros. El VIF no debe verse como un obstáculo final, sino como una alerta sobre decisiones tomadas desde el diseño (Hair et al., 2021).

Considerar el sesgo de método común. Este riesgo aparece cuando las variables se miden con el mismo instrumento, al mismo tiempo y a partir del mismo informante, lo que puede inflar artificialmente las relaciones entre constructos. En ciencias de la administración, esto es frecuente porque muchos estudios utilizan cuestionarios autoadministrados. Antes del análisis estructural, el investigador debe reconocer este riesgo y anticipar estrategias de prevención. Algunas decisiones conceptuales ayudan: separar secciones del cuestionario, cuidar la redacción, reducir ambigüedad, usar diferentes fuentes cuando sea posible, garantizar anonimato y evitar preguntas que induzcan respuestas socialmente deseables. Si todas las variables provienen del mismo encuestado y usan escalas similares, el investigador debe reconocerlo como limitación potencial. Antes del análisis estructural, debe preguntarse: **¿mis datos provienen de una sola fuente?, ¿puedo diversificar fuentes?, ¿el diseño del instrumento reduce sesgos?, ¿la interpretación reconocerá este riesgo?** (Gefen et al., 2000).

Estimar de manera preliminar el tamaño de muestra y la potencia estadística, Aquí, el investigador no debe esperar al final para preguntarse si tendrá datos suficientes. La muestra depende de la complejidad del modelo, el número de constructos, indicadores, relaciones estructurales, mediaciones, moderaciones y tamaño esperado de los efectos. Un modelo muy complejo con muestra pequeña puede producir resultados inestables. La potencia estadística permite evaluar la capacidad del estudio para detectar efectos reales. En términos formativos, el investigador debe comprender que no basta con recolectar “las encuestas posibles”; debe planear una muestra compatible con su modelo. Antes del análisis estructural, debe responder: **¿cuántos casos puedo obtener?, ¿mi modelo es proporcional a esa muestra?, ¿hay demasiadas relaciones para el tamaño disponible?, ¿debo simplificar el modelo?, ¿qué nivel de poder estadístico necesito?**. Esta condición conecta diseño conceptual y viabilidad empírica. Una buena arquitectura conceptual también debe ser estimable con los datos disponibles (Hair et al., 2021).

Verificar la coherencia entre propósito, técnica e índices. Si el propósito es explicar relaciones, deben cuidarse coeficientes *path*, R^2 y f^2 . Si el propósito es predecir, deben incorporarse Q^2 y criterios predictivos. Si el propósito es validar medición, deben revisarse confiabilidad, AVE y HTMT. Si hay constructos formativos, deben observarse pesos y VIF. Esta coherencia evita usar índices sin comprender su función.. Por ejemplo, $\boldsymbol{R^2}$ indica varianza explicada; $\boldsymbol{f^2}$ muestra tamaño del efecto; $\boldsymbol{Q^2}$ aporta evidencia de relevancia predictiva; **SRMR** puede orientar ajuste aproximado;

HTMT evalúa discriminación entre constructos; **VIF** alerta sobre colinealidad. Estos índices no deben memorizarse como lista, sino entenderse como respuestas a preguntas metodológicas. Antes de modelar, el investigador debe saber qué índices serán relevantes según su propósito. Esta condición prepara una transición ordenada hacia SmartPLS y evita interpretaciones mecánicas (Shmueli, 2010).

Contar con un diagrama conceptual preliminar. Este diagrama no es todavía el modelo definitivo de software, sino una representación visual de la arquitectura conceptual. Debe mostrar la variable dependiente, variables explicativas, mediadores, moderadores y dirección esperada de las relaciones. Su función es ayudar al investigador a detectar incoherencias antes del análisis. Si el diagrama está saturado de flechas, quizá el modelo necesita simplificarse. Si aparecen variables sin conexión clara, deben revisarse. Si hay relaciones sin fundamento teórico, deben eliminarse o justificarse mejor. El diagrama preliminar también permite revisar si la pregunta estructural, los objetivos y las hipótesis coinciden. En enseñanza, este paso es fundamental porque obliga al investigador a ver el modelo como sistema, no como lista de variables. Antes de abrir SmartPLS, el investigador debe poder explicar su diagrama oralmente: **qué significa cada constructo, por qué cada flecha existe, qué variable se explica y qué índices serán relevantes después**. Si no puede explicarlo sin software, el modelo no está listo (Gefen et al., 2000).

La condición final es aplicar un checklist de preparación antes del análisis estructural. Este checklist debe confirmar que el estudio tiene: idea delimitada, fenómeno claro, problema justificado, pregunta estructural, propósito definido, unidad de análisis, contexto, variable dependiente, variables explicativas, constructos definidos, indicadores preliminares, tipo de medición, hipótesis, muestra estimable, riesgos metodológicos identificados y técnica SEM probable. Si alguno de estos elementos falta, conviene corregirlo antes de avanzar. Este cierre del Capítulo 1 cumple una función pedagógica de la impiortancia de la construcción rigurosa del modelo conceptual. En síntesis, las condiciones mínimas antes del análisis estructural son una garantía de coherencia. Un buen modelo no es aquel que produce muchos resultados, sino aquel que puede defender cada decisión antes, durante y después del análisis (Mejía-Trejo, 2023).

Conclusiones

El capítulo 1 establece la base lógica de todo modelo SEM: **antes de estimar relaciones estadísticas, el investigador debe construir una arquitectura conceptual clara, delimitada, medible y metodológicamente viable**. La idea inicial, por sí sola, no posee todavía valor analítico suficiente; requiere transformarse en un fenómeno investigable, situado en una unidad de análisis, vinculado con un contexto específico y orientado hacia una variable central que pueda explicarse o predecirse. Desde esta perspectiva, el capítulo muestra que el rigor de un modelo estructural no comienza con el uso de SmartPLS, AMOS, LISREL, EQS o R, sino con la capacidad del investigador para convertir una inquietud amplia en un sistema coherente de problema, pregunta, constructos, indicadores e hipótesis.

Asimismo, el capítulo permite comprender que el tránsito del fenómeno al problema estructural es decisivo, porque el fenómeno solo indica qué parte de la realidad será observada, mientras que el problema expresa la **tensión científica** que justifica investigarla. Por ello, un buen problema no debe limitarse a describir una situación administrativa; debe identificar un vacío teórico, empírico, metodológico o práctico, y convertirlo en una relación modelable. De esta forma, la pregunta de investigación adquiere una función articuladora: conecta el problema con las relaciones estructurales que posteriormente serán representadas mediante variables dependientes, independientes, mediadoras, moderadoras o de control.

El capítulo también enfatiza que los conceptos no pueden incorporarse directamente al modelo SEM sin pasar por un proceso de definición, delimitación y operacionalización. Conceptos como innovación, confianza, aprendizaje organizacional, sostenibilidad, desempeño o capacidades digitales requieren convertirse en variables o constructos, y estos deben representarse mediante indicadores pertinentes. Esta transición es fundamental porque muchos errores estadísticos posteriores —baja confiabilidad, colinealidad, falta de validez discriminante o constructos redundantes— tienen origen en una conceptualización débil. En consecuencia, la calidad del análisis SEM depende de la coherencia entre concepto, definición, dimensión, indicador, ítem, escala y referencia de base.

El capítulo concluye que todo modelo debe someterse a una revisión de **viabilidad conceptual, empírica y metodológica**. No basta con que el modelo sea interesante; debe ser posible medirlo, estimarlo e interpretarlo con datos adecuados. Esta revisión obliga a verificar si la unidad de análisis es congruente con los indicadores, si la muestra probable será suficiente, si los constructos son diferenciables, si las hipótesis son defendibles y si la técnica SEM seleccionada corresponde al propósito del estudio. Así, el capítulo deja una idea central: **un buen modelo estructural no nace del software, sino de una pregunta bien formulada, constructos bien definidos, relaciones justificadas y una estrategia metodológica viable**. Váse **Tabla 1.**

Tabla 1. La idea antes del modelo

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Alfa de Cronbach	Índice de consistencia interna utilizado principalmente en constructos reflectivos. Evalúa si los ítems de una escala mantienen coherencia entre sí como manifestaciones	Permite valorar preliminarmente la confiabilidad de una escala antes de interpretar relaciones estructurales.	Valores iguales o superiores a .70 suelen considerarse aceptables en investigaciones consolidadas; sin embargo, no debe usarse de manera aislada ni sustituir la validez conceptual del constructo.	Churchill, 1979; Hair et al., 2019

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	de un mismo constructo.			
AVE	La varianza media extraída indica la proporción de varianza que un constructo explica en sus indicadores. Es un criterio de validez convergente.	Evalúa si los indicadores representan adecuadamente el constructo latente al que pertenecen.	Un AVE ≥ .50 suele interpretarse como evidencia de que el constructo explica más varianza de sus indicadores que el error de medición.	Hair et al., 2019; Hair et al., 2021
CB-SEM	Enfoque de ecuaciones estructurales basado en covarianzas. Se orienta principalmente a la confirmación teórica y a la evaluación del ajuste global del modelo.	Se utiliza cuando el investigador busca contrastar modelos teóricos consolidados y evaluar la correspondencia entre matriz teórica y matriz empírica.	Es pertinente cuando existe teoría fuerte, especificación previa clara y propósito confirmatorio.	Gefen et al., 2000; Hair et al., 2021
Colinealidad	Situación en la que dos o más indicadores o constructos están excesivamente relacionados entre sí, generando redundancia conceptual o inestabilidad estadística.	Ayuda a detectar si los indicadores formativos o las variables explicativas se solapan de forma problemática.	Puede anticiparse desde la conceptualización : constructos demasiado parecidos o indicadores redundantes tienden a producir problemas de colinealidad.	Hair et al., 2019; Henseler et al., 2015
Concepto	Noción general que permite nombrar un fenómeno, como innovación, liderazgo, confianza o sostenibilidad. Todavía no es medible por sí mismo.	Es el punto de partida conceptual que debe transformarse en variable o constructo antes de incorporarse al modelo SEM.	Un concepto debe delimitarse antes de ser medido; nombrarlo no equivale a construir una variable ni un constructo.	Churchill, 1979; Mejía-Trejo, 2023
Constructo	Entidad teórica que representa un fenómeno no	Permite modelar realidades abstractas dentro	Debe tener dominio conceptual claro,	Jarvis et al., 2003; Hair et al., 2021

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	observable directamente, pero inferible mediante indicadores.	de SEM, como confianza, satisfacción, aprendizaje organizacional o desempeño innovador.	límites definidos, indicadores pertinentes y diferenciación frente a otros constructos.	
Constructo compuesto	Constructo construido a partir de indicadores que actúan como componentes de una entidad analítica.	Se utiliza para representar fenómenos donde los indicadores integran el constructo, más que reflejar una causa latente común.	Debe especificarse conceptualmente desde el diseño; no debe decidirse solo por conveniencia estadística.	Hair et al., 2021; Henseler, 2017
Constructo formativo	Constructo en el que los indicadores forman o componen el fenómeno. Los indicadores no necesariamente son intercambiables ni deben correlacionarse fuertemente.	Permite medir fenómenos integrados por componentes diferenciados, como recursos, capacidades o niveles compuestos.	Eliminar un indicador puede modificar el significado del constructo; por ello, la especificación conceptual es decisiva.	Diamantopoulos & Winklhofer, 2001; Jarvis et al., 2003
Constructo reflectivo	Constructo en el que el fenómeno latente causa sus indicadores. Si el constructo cambia, los indicadores deberían cambiar en la misma dirección.	Es común en escalas de percepción, actitud, satisfacción, confianza o compromiso.	Los indicadores deben ser conceptualmente intercambiables, correlacionarse entre sí y reflejar una misma realidad latente.	Hair et al., 2021; Jarvis et al., 2003
Dimensión	Componente conceptual interno de un constructo amplio. Organiza su complejidad sin fragmentarlo arbitrariamente.	Permite estructurar constructos multidimensionales, como sostenibilidad, transformación digital o capacidad de innovación.	Cada dimensión debe tener significado propio, indicadores pertinentes y relación clara con el constructo superior.	Henseler, 2017; Jarvis et al., 2003
Fenómeno investigable	Manifestación específica de un tema general	Es el primer paso para construir un modelo SEM,	Debe precisar qué ocurre, dónde ocurre, a	Mejía-Trejo, 2023

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	que puede observarse, delimitarse y analizarse empíricamente.	porque permite pasar de una idea amplia a un objeto de estudio medible.	quién afecta, por qué importa y qué relación podría analizarse.	
Hipótesis estructural	Respuesta tentativa a la pregunta de investigación, expresada como relación esperada entre variables o constructos.	Se representa en SEM mediante rutas o flechas entre constructos.	Debe derivarse del problema, la pregunta y la teoría; no debe surgir solo de la disponibilidad de variables o datos.	Hair et al., 2021; Gefen et al., 2000
HTMT	Criterio de razón heterotrait-monotrait utilizado para evaluar validez discriminante entre constructos.	Permite identificar si dos constructos están empíricamente demasiado próximos.	Valores altos sugieren posible falta de diferenciación conceptual; el problema suele originarse en definiciones o indicadores solapados.	Henseler et al., 2015; Hair et al., 2019
Indicador	Manifestación observable que permite medir una variable o constructo. Puede expresarse como ítem, dato objetivo o componente empírico.	Conecta la definición conceptual del constructo con la evidencia empírica.	Debe ser claro, específico, congruente con la unidad de análisis y trazable a una definición o referencia.	Churchill, 1979; Mejía-Trejo, 2023
Mediación	Relación en la que una variable intermedia explica el mecanismo mediante el cual una variable independiente influye en una dependiente.	Permite representar el "cómo" o "por qué" ocurre una relación estructural.	Requiere justificación teórica y lógica temporal: X influye en M, y M influye en Y.	Hair et al., 2021; Nitzl et al., 2016
Modelo de medición	Parte del SEM que especifica cómo los constructos se relacionan con sus indicadores.	Evalúa la calidad de la medición antes de interpretar las relaciones estructurales.	Debe corresponder al tipo de constructo: reflectivo, formativo o compuesto.	Hair et al., 2021; Jarvis et al., 2003

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Modelo estructural	Parte del SEM que representa las relaciones entre constructos o variables.	Permite evaluar hipótesis, efectos directos, indirectos, mediaciones, moderaciones y capacidad explicativa o predictiva.	Debe derivarse de una pregunta estructural clara y de relaciones justificadas teóricamente.	Chin, 1998; Gefen et al., 2000
Moderación	Relación en la que una variable modifica la intensidad o dirección de la relación entre una variable independiente y una dependiente.	Permite representar el "cuándo", "para quién" o "bajo qué condiciones" ocurre una relación.	Debe justificarse conceptualmente; no debe agregarse solo para sofisticar el modelo.	Gefen et al., 2000; Hair et al., 2021
Operacionalización	Proceso mediante el cual un concepto abstracto se traduce en dimensiones, indicadores, ítems y escalas de medición.	Hace posible convertir constructos teóricos en datos analizables mediante SEM.	Debe mantener trazabilidad entre literatura, definición, dimensión, indicador e instrumento.	Churchill, 1979; Mejía-Trejo, 2023
PLS-SEM	Enfoque de ecuaciones estructurales basado en varianza o componentes, comúnmente orientado a explicación-predicción y modelos complejos.	Se utiliza para analizar relaciones entre constructos, especialmente cuando el objetivo incluye capacidad explicativa y predictiva.	Es pertinente cuando el estudio busca explicar o predecir resultados, trabajar con modelos complejos o constructos compuestos.	Hair et al., 2019; Hair et al., 2021
Pregunta estructural	Pregunta de investigación que expresa una relación posible entre variables o constructos.	Funciona como puente entre el problema y el modelo estructural.	Debe contener una variable resultado, una o más variables explicativas, unidad de análisis y contexto.	Hair et al., 2021; Mejía-Trejo, 2023
Problema estructural	Tensión científica que justifica estudiar un fenómeno mediante	Orienta la selección de variables, hipótesis,	Debe identificar un vacío, una relación insuficientemente comprendida y	Gefen et al., 2000; Mejía-Trejo, 2023

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	relaciones entre variables o constructos.	indicadores y técnica SEM.	una consecuencia administrativa relevante.	
R^2	Coeficiente de determinación que indica la proporción de varianza explicada en una variable dependiente.	Evalúa la capacidad explicativa del modelo estructural sobre los constructos endógenos.	Valores más altos sugieren mayor explicación, pero no sustituyen la justificación teórica ni prueban causalidad fuerte por sí mismos.	Hair et al., 2019; Shmueli, 2010
Tema de investigación	Campo general de interés, como liderazgo, innovación, sostenibilidad o transformación digital.	Sirve como punto de partida, pero aún no constituye un objeto modelable en SEM.	Debe transformarse en fenómeno, problema, pregunta y variables antes de ser analizado estructuralmente.	Mejía-Trejo, 2023
Unidad de análisis	Sujeto, grupo, organización, institución, territorio o sistema sobre el cual se recolectan e interpretan los datos.	Define quién o qué será observado y a qué nivel se interpretarán las relaciones SEM.	Debe ser congruente con los indicadores y constructos; no debe mezclarse nivel individual, organizacional o regional sin justificación.	Gefen et al., 2000; Hair et al., 2021
Validez discriminante	Evidencia de que un constructo es conceptualmente y empíricamente distinto de otros constructos del modelo.	Permite verificar que el modelo no mide la misma realidad con nombres diferentes.	Debe anticiparse desde definiciones diferenciadas; HTMT puede ayudar a diagnosticar problemas.	Henseler et al., 2015; Jarvis et al., 2003
Validez predictiva	Capacidad del modelo para anticipar valores o resultados en observaciones nuevas o relevantes.	Es especialmente importante cuando el propósito del estudio incluye predicción.	No debe confundirse con explicación teórica; un modelo puede explicar varianza sin necesariamente predecir bien.	Hair et al., 2019; Shmueli, 2010
Variable dependiente	Variable resultado que se desea explicar o predecir.	Organiza la dirección del modelo estructural y permite seleccionar antecedentes,	Debe estar claramente vinculada con el problema y la pregunta de investigación.	Hair et al., 2021; Mejía-Trejo, 2023

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
		mediadores o moderadores.		
Variable independiente	Variable explicativa que actúa como antecedente de una variable dependiente.	Representa factores que podrían influir en el resultado central del modelo.	Su inclusión debe justificarse teóricamente; no debe elegirse por moda o disponibilidad de escalas.	Gefen et al., 2000; Hair et al., 2021
VIF	Factor de inflación de la varianza; índice usado para diagnosticar colinealidad.	Ayuda a valorar si indicadores o variables explicativas están excesivamente correlacionados.	Valores elevados indican posible redundancia; su interpretación depende del tipo de modelo y de la especificación conceptual.	Hair et al., 2019; Hair et al., 2021

Fuente: elaboración propia

CAPÍTULO 2. Sistema conceptual y lógica del modelo

El Capítulo 2 plantea que **el problema de investigación no debe entenderse como una simple descripción temática**, sino como la **tensión científica que da origen al modelo**. Un problema bien formulado identifica qué falta explicar, predecir, medir o contextualizar, y permite traducir esa ausencia en una primera arquitectura de variables, constructos y relaciones. Por ello, antes de avanzar hacia técnicas SEM, el investigador debe demostrar que el problema puede convertirse en un sistema conceptual coherente, medible y defendible (Gefen et al., 2000).

En segundo lugar, el capítulo sostiene que **el sistema conceptual funciona como puente entre el problema y el modelo estructural**. No es todavía el diagrama definitivo ni el análisis estadístico, sino una representación razonada de cómo se entiende el fenómeno. En esta etapa se define la variable central, se seleccionan antecedentes pertinentes, se anticipan mecanismos mediadores, se reconocen posibles condiciones moderadoras y se delimita la lógica general de relación entre constructos (Hair et al., 2021)

Asimismo, se plantea que **todo modelo debe partir de un vacío de investigación claramente identificado**. Los vacíos teórico, empírico, metodológico y práctico no son etiquetas decorativas, sino razones académicas que justifican la investigación. El vacío teórico fortalece la explicación conceptual; el empírico justifica estudiar un contexto específico; el metodológico señala limitaciones en la forma de medir o analizar; y el práctico conecta el modelo con necesidades reales de organizaciones, instituciones o mercados (Guenther et al., 2023).

Otra conclusión relevante es que **explicar y predecir no son equivalentes**. La explicación busca comprender por qué ocurre un fenómeno y mediante qué mecanismos se produce; la predicción busca anticipar un resultado con base en sus antecedentes. En ciencias de la administración, ambos propósitos pueden combinarse, pero deben declararse con claridad desde el diseño, porque afectan la pregunta de investigación, la selección de variables, la formulación de hipótesis y la interpretación posterior del modelo (Shmueli, 2010).

Como orientación general, el capítulo permite afirmar que **la calidad de un modelo SEM depende de la claridad conceptual previa, no solo de los indicadores estadísticos posteriores**. Un modelo no es más sólido por incluir más variables, más flechas o más relaciones, sino por integrar únicamente los elementos necesarios para responder el problema. La parsimonia, la viabilidad, la unidad de análisis, el contexto y la coherencia entre problema, vacío, pregunta, variables e hipótesis son condiciones indispensables para avanzar hacia un modelo estructural riguroso. En este sentido, el Capítulo 2 prepara la construcción del sistema conceptual preliminar antes del modelo SEM y evita que el investigador confunda el uso del software con la fundamentación científica del modelo (Hair et al., 2021)

Del problema de investigación al sistema conceptual

El **problema de investigación** constituye el punto de partida formal para construir un **sistema conceptual**. Mientras el fenómeno indica qué parte de la realidad será observada, el problema expresa una **tensión científica**: **algo no está suficientemente explicado, relacionado, medido o contextualizado**. En ciencias de la administración, esta tensión puede surgir de contradicciones entre teoría y práctica, vacíos empíricos, falta de modelos explicativos, problemas de medición o necesidad de anticipar resultados organizacionales. Sin embargo, un problema no debe quedarse como descripción general: para conducir a un modelo SEM, debe traducirse en una estructura inicial de **variables, constructos y relaciones**. Esto exige identificar qué resultado se desea explicar o predecir, qué factores podrían influir en él, qué relación tiene sentido conceptual y qué evidencia permitiría sostener el análisis. Así, el problema no es únicamente una sección introductoria del estudio; es la **matriz lógica** desde la cual derivan pregunta, objetivos, hipótesis, constructos e indicadores. Un problema bien formulado evita modelos improvisados y permite avanzar hacia una arquitectura conceptual clara, medible y defendible. Por ello, antes de pensar en

software, índices o estimaciones, el investigador debe asegurarse de que el problema pueda convertirse en una relación estructural justificable entre conceptos relevantes (Gefen et al., 2000). Así, debenos considerar:

El **sistema conceptual** es la organización preliminar de los elementos que explican o predicen el fenómeno de interés. No es todavía el modelo estadístico ni el diagrama definitivo en SmartPLS, AMOS, EQS, LISREL o R; más bien, es una representación razonada de cómo el investigador entiende el problema. En este sistema se identifica una **variable central**, se seleccionan posibles **variables explicativas**, se anticipan mecanismos mediadores o condiciones moderadoras, y se define la lógica de relación entre constructos. La importancia de esta etapa radica en que SEM no debe utilizarse para buscar relaciones al azar, sino para evaluar relaciones previamente justificadas. Por ello, el sistema conceptual funciona como puente entre el problema y el análisis estructural. Antes de calcular cargas, AVE, HTMT, VIF, coeficientes *path*, R^2 o Q^2, el investigador debe saber qué está modelando y por qué. En PLS-SEM, esta claridad es especialmente relevante porque el método suele emplearse en modelos complejos, con orientación explicativa-predictiva y énfasis en varianza explicada; sin embargo, esa flexibilidad no elimina la necesidad de una estructura conceptual rigurosa. Un modelo flexible no debe confundirse con un modelo arbitrario. La flexibilidad metodológica solo es útil cuando descansa sobre una **arquitectura conceptual coherente** (Hair et al., 2021).

El paso del problema al sistema conceptual exige distinguir entre **explicación** y **predicción**. Un problema explicativo busca comprender por qué ocurre un fenómeno; por ejemplo, por qué ciertas empresas logran mayor desempeño innovador que otras. Un problema predictivo busca anticipar un resultado; por ejemplo, qué combinación de factores permite prever la intención de adopción tecnológica, la satisfacción del cliente o el desempeño organizacional. Esta diferencia modifica la forma de construir el sistema conceptual. Si el propósito es explicar, las variables deben seleccionarse por su fuerza teórica y por su capacidad para revelar mecanismos. Si el propósito es predecir, las variables deben seleccionarse también por su capacidad para anticipar resultados con precisión empírica. En ambos casos, el investigador debe evitar confundir significancia estadística con sentido teórico. Un sistema conceptual robusto no solo incluye variables relacionadas, sino variables que cumplen una función clara dentro del modelo. Por ello, desde el problema debe declararse si la investigación busca **explicar, predecir o combinar ambos propósitos**. Esta decisión no es secundaria: orienta la pregunta, las hipótesis, la selección de técnica, la interpretación de resultados y el tipo de contribución esperada. La confusión entre explicación y predicción puede producir modelos aparentemente sólidos, pero metodológicamente ambiguos (Shmueli, 2010).

La construcción del sistema conceptual requiere atender las buenas prácticas contemporáneas del uso de PLS-SEM en investigación administrativa. Uno de los riesgos frecuentes consiste en aplicar PLS-SEM de manera mecánica, sin justificar suficientemente por qué la técnica es pertinente para el problema, el propósito y la estructura del modelo. Un sistema conceptual bien construido debe mostrar que las

relaciones no se agregan por conveniencia, sino por su contribución a la comprensión del fenómeno. Además, debe evitar **modelos sobredimensionados**, constructos redundantes y relaciones sin fundamento. La calidad del sistema conceptual se refleja en la claridad de las hipótesis, la pertinencia de los constructos, la coherencia de la unidad de análisis y la posibilidad de evaluación empírica. Por tanto, el problema debe convertirse en una arquitectura capaz de distinguir **antecedentes, consecuencias, mecanismos y condiciones**. Esta arquitectura prepara al investigador para entender que el SEM no empieza en el software, sino en la lógica conceptual que sostiene el modelo. También ayuda a evitar prácticas débiles, como seleccionar el SEM solo por moda, por facilidad de uso o porque tolera modelos complejos. La complejidad debe justificarse; de lo contrario, el modelo puede perder claridad, parsimonia y valor explicativo (Guenther et al., 2023). Con lo anterior, es posible definir los siguientes componentes de un sistema conceptual:

La variable central. Esta representa el resultado principal que el investigador desea explicar o predecir. Puede tratarse de innovación, desempeño, satisfacción, lealtad, intención de uso, productividad, competitividad, resiliencia, aprendizaje, sostenibilidad o adopción tecnológica. Su función es dar dirección al modelo. Sin una variable central, el sistema conceptual se vuelve disperso, porque no queda claro hacia dónde se orientan las relaciones. Por ejemplo, si el problema señala que las pequeñas empresas enfrentan dificultades para innovar en contextos digitales, la variable central podría ser el **desempeño innovador**. A partir de ella se seleccionan variables que podrían explicarlo, como capacidades digitales, aprendizaje organizacional, cultura innovadora o liderazgo tecnológico. Esta decisión es clave porque evita que el modelo se construya como una lista de variables atractivas pero desconectadas. La variable central opera como eje de coherencia: todo antecedente, mediador o moderador debe justificar su presencia en relación con ella. Además, permite distinguir entre relaciones necesarias y relaciones accesorias. Un sistema conceptual sólido no inicia preguntando cuántas variables pueden agregarse, sino qué resultado requiere explicación y qué factores son pertinentes para comprenderlo (Gefen et al., 2000).

Las variables explicativas. Estas representan factores que pueden influir, anticipar o ayudar a comprender la variable central. Su selección debe responder a una lógica conceptual, no a moda académica ni a disponibilidad de escalas. Una variable explicativa debe incorporarse porque aporta una razón plausible para entender el problema. Por ejemplo, si se estudia el desempeño innovador, las capacidades digitales podrían ser una variable explicativa porque permiten procesar información, mejorar procesos, aprender del entorno y generar soluciones. Sin embargo, no basta con afirmar que una variable “influye”; debe explicarse **por qué, cómo y bajo qué condiciones** podría hacerlo. Esta justificación evita que el sistema conceptual se convierta en un inventario de constructos. Un buen sistema conceptual no incluye todas las variables posibles, sino las necesarias. La **parsimonia** es una condición de calidad: cada variable debe tener función, lugar y sentido dentro del modelo. Además, las variables explicativas deben ser conceptualmente distinguibles entre sí. Si dos variables expresan prácticamente lo mismo, pueden generar redundancia y dificultar la interpretación posterior. En este punto, el investigador debe aprender que un modelo

más grande no es necesariamente mejor; un modelo es mejor cuando sus elementos son pertinentes, diferenciados y coherentes (Hair et al., 2021).

Las relaciones conceptuales. Una relación conceptual es una conexión razonada entre dos constructos. En un sistema estructural, esta relación suele representarse después mediante una flecha, pero la flecha solo es válida si existe una justificación previa. Las relaciones pueden ser directas, cuando una variable influye sobre otra; indirectas, cuando el efecto ocurre por medio de un mecanismo; o condicionadas, cuando la relación cambia según una variable moderadora. Por ejemplo, las capacidades digitales pueden relacionarse directamente con el desempeño innovador; también pueden influir indirectamente mediante el aprendizaje organizacional; o su efecto puede depender del nivel de turbulencia ambiental. Estas posibilidades no deben agregarse por sofisticación, sino porque el problema lo requiere. Cada relación debe responder una pregunta: **¿qué aporta esta conexión para comprender el fenómeno?** Si la respuesta no es clara, la relación debe revisarse o eliminarse. Este razonamiento ayuda a prevenir modelos decorativos, donde las flechas se multiplican sin función teórica. También ayuda a distinguir entre asociación, explicación y predicción. No toda relación estadísticamente posible es conceptualmente necesaria, y no toda relación conceptualmente atractiva será empíricamente viable. La construcción del sistema conceptual exige equilibrio entre teoría, propósito y posibilidad de evaluación (Shmueli, 2010).

La calidad de la justificación metodológica. No basta con que el modelo parezca lógico; debe poder defenderse frente a criterios de investigación aplicada. En negocios, marketing, administración y sistemas de información, el uso de SEM exige claridad sobre la naturaleza del modelo, la razón de uso de la técnica y la contribución esperada. Por ello, el sistema conceptual debe evitar tres debilidades: **relaciones sin fundamento**, **constructos redundantes** y **selección automática de técnica**. La primera ocurre cuando el investigador dibuja flechas sin explicar su sentido. La segunda aparece cuando varios constructos capturan el mismo contenido conceptual. La tercera surge cuando se elige SEM solo porque es popular o porque el software resulta accesible. Frente a estos riesgos, el sistema conceptual debe mostrar que cada elemento tiene una función. Además, debe ser consistente con el propósito del estudio: explicación, predicción, confirmación parcial, desarrollo conceptual o evaluación de relaciones complejas. Esta consistencia fortalece la defensa del modelo antes de cualquier resultado estadístico. En términos pedagógicos, el capítulo debe formar al investigador para justificar el modelo antes de estimarlo; es decir, para demostrar que el análisis estructural será consecuencia del razonamiento metodológico y no un ejercicio mecánico (Guenther et al., 2023).

La lógica de mediación. Una mediación permite explicar el mecanismo mediante el cual una variable independiente afecta una variable dependiente. En lugar de limitarse a decir que X influye en Y, la mediación pregunta **cómo ocurre esa influencia**. Por ejemplo, si las capacidades digitales mejoran el desempeño innovador, el aprendizaje organizacional podría explicar parte de ese vínculo, porque las tecnologías solo generan valor cuando la organización aprende a usarlas, integrarlas

y convertirlas en conocimiento aplicado. En este caso, el aprendizaje organizacional no es una variable adicional decorativa, sino un mecanismo que ayuda a comprender el proceso. La mediación es especialmente útil cuando el problema no solo busca identificar antecedentes, sino explicar rutas de transformación. No obstante, debe usarse con prudencia. Incluir mediadores sin fundamento puede hacer que el modelo parezca sofisticado, pero conceptualmente débil. La mediación debe surgir del problema, no del deseo de aumentar complejidad. Además, debe tener sentido temporal y conceptual: la variable mediadora debe ubicarse razonablemente entre el antecedente y el resultado. En el sistema conceptual, la mediación cumple una función explicativa; en capítulos posteriores podrá traducirse en hipótesis y análisis de efectos indirectos (Gefen et al., 2000).

La lógica de moderación. Una moderación permite analizar si una relación cambia según una condición específica. Mientras la mediación responde al **cómo** o **por qué**, la moderación responde al **cuándo**, **para quién** o **bajo qué condiciones**. En ciencias de la administración, esta lógica es relevante porque los fenómenos organizacionales no ocurren de manera uniforme. Una relación entre capacidades digitales e innovación puede ser más fuerte en entornos altamente competitivos que en entornos estables. La relación entre liderazgo y desempeño puede variar según cultura organizacional, tamaño de empresa o nivel de incertidumbre. Por ello, el sistema conceptual puede incluir moderadores cuando el problema exige explicar diferencias contextuales. Sin embargo, al igual que la mediación, la moderación debe justificarse. No toda variable contextual debe convertirse en moderadora. Su inclusión debe aportar una comprensión adicional del fenómeno y no solo aumentar el número de interacciones. También debe considerarse la viabilidad del modelo: las moderaciones suelen exigir mayor claridad conceptual, suficiente muestra y capacidad de interpretación. En esta etapa no se agota el análisis técnico, pero sí se establece que toda moderación debe responder a una condición teórica o contextual relevante, no a una intención de complejidad artificial (Hair et al., 2021).

La unidad de análisis. Un sistema conceptual sólido debe aclarar si el modelo se refiere a individuos, equipos, empresas, instituciones, proyectos, cadenas de suministro, regiones o ecosistemas. Esta decisión es fundamental porque determina cómo se interpretan las variables y qué tipo de datos se requieren. No es lo mismo estudiar la intención individual de adoptar tecnología que estudiar la capacidad digital de una empresa. Tampoco es equivalente medir satisfacción de empleados que desempeño organizacional. La unidad de análisis debe estar alineada con el problema y con la forma en que se recolectarán los datos. Si el modelo plantea relaciones a nivel organizacional, los datos deben representar a la organización. Si se usan respuestas individuales para inferir atributos empresariales, debe existir una justificación metodológica. La unidad de análisis protege la coherencia del sistema conceptual y evita inferencias indebidas. En términos pedagógicos, ayuda al investigador a entender que el modelo no flota en abstracto: siempre se refiere a un nivel específico de realidad. Además, esta decisión tiene implicaciones para la medición, la muestra y la interpretación. Un modelo puede ser conceptualmente interesante, pero metodológicamente débil si mezcla niveles sin explicación suficiente (Shmueli, 2010).

El contexto. Todo sistema conceptual debe indicar dónde ocurre el problema y por qué ese contexto importa. En administración, el contexto puede modificar la forma en que se comportan las relaciones. Las pymes no tienen los mismos recursos que las grandes empresas; las organizaciones públicas no operan bajo la misma lógica que las privadas; las startups tecnológicas enfrentan condiciones diferentes a las empresas tradicionales. Por ello, el contexto no debe aparecer como un dato secundario, sino como una condición de interpretación. Si el problema se ubica en pymes, el sistema conceptual debe reconocer sus limitaciones de recursos, flexibilidad, informalidad o capacidad de adaptación. Si se ubica en empresas digitales, debe considerar madurez tecnológica, presión competitiva y capacidades analíticas. El contexto delimita el alcance del modelo y evita generalizaciones excesivas. Además, puede justificar por qué una relación merece estudiarse en un grupo específico y no de manera universal. En investigación con SEM, esta claridad contextual mejora la pertinencia del modelo y reduce el riesgo de aplicar plantillas genéricas. Un sistema conceptual debe responder no solo qué relación se estudia, sino **dónde, para quién y bajo qué condiciones** esa relación adquiere sentido (Guenther et al., 2023).

La coherencia entre problema, pregunta y sistema conceptual. Un error frecuente consiste en formular un problema, redactar una pregunta y diseñar un modelo que no corresponden entre sí. Por ejemplo, el problema puede centrarse en desempeño innovador, pero el modelo termina incluyendo satisfacción, liderazgo, competitividad y cultura sin explicar cómo se articulan. Esta desconexión debilita el estudio. El sistema conceptual debe derivarse de la pregunta estructural y, a su vez, la pregunta debe derivarse del problema. Si el problema afirma que no se comprende la relación entre capacidades digitales y desempeño innovador, el sistema conceptual debe organizarse alrededor de esa relación. Si se agregan mediadores o moderadores, deben fortalecer esa lógica. La coherencia implica que cada parte del diseño responda a la misma intención investigativa. En términos prácticos, el investigador debe poder explicar su sistema conceptual en pocas frases: **qué estudia, qué quiere explicar, qué variables usa y por qué esas relaciones tienen sentido**. Esta capacidad de explicación es una prueba inicial de calidad. Si el investigador no puede explicar el sistema sin recurrir al software, entonces el sistema todavía no está listo para ser estimado (Gefen et al., 2000).

La delimitación de constructos. Un constructo es un concepto abstracto que requiere definición antes de ser medido. En el sistema conceptual, los constructos no deben aparecer como etiquetas generales. Deben tener un significado específico dentro del estudio. Por ejemplo, “transformación digital” puede referirse a adopción tecnológica, capacidades digitales, madurez digital, cultura digital o automatización de procesos. Si el investigador no define qué entiende por el constructo, el modelo se vuelve ambiguo. Lo mismo ocurre con innovación, desempeño, confianza o aprendizaje. Cada constructo debe tener límites conceptuales: qué incluye, qué excluye y cómo se relaciona con otros constructos. Esta delimitación prepara el camino para los capítulos posteriores, donde se profundizará en medición e indicadores. En este capítulo no se agotan los criterios técnicos; solo se establece que un sistema conceptual no puede sostenerse sobre conceptos vagos. La claridad conceptual es la

base de la medición futura. Además, en SEM es importante que el investigador comprenda que la forma en que define el constructo influirá en su especificación posterior. Por eso, el sistema conceptual debe ser lo bastante claro para guiar la operacionalización sin adelantar todavía todos los detalles técnicos (Hair et al., 2021).

La relación entre constructos e indicadores. Aunque el capítulo 2 no debe agotar el tema de medición, sí debe dejar claro que todo sistema conceptual debe ser potencialmente medible. Si un constructo no puede representarse mediante indicadores, datos o escalas, difícilmente podrá incorporarse a un modelo SEM. Esto no significa definir todavía cada ítem, pero sí anticipar que cada concepto deberá traducirse en evidencia observable. Por ejemplo, si se propone estudiar aprendizaje organizacional, el investigador debe prever si podrá medirlo mediante percepciones, prácticas, rutinas, capacidades o indicadores objetivos. Si se estudia desempeño innovador, debe decidir si lo representará mediante nuevos productos, mejoras de proceso, percepción directiva o resultados documentados. Esta anticipación evita construir modelos conceptualmente atractivos pero empíricamente inviables. El sistema conceptual debe ser teórico, pero también operable. La medición no se desarrolla plenamente aquí, pero su posibilidad debe estar presente. Desde la lógica explicación-predicción, esta relación es central: una variable mal representada puede afectar tanto la interpretación teórica como la capacidad predictiva. Por ello, todo constructo incluido debe tener una ruta razonable hacia datos observables (Shmueli, 2010).

La viabilidad del sistema conceptual. No todo sistema teóricamente interesante puede ejecutarse con los recursos disponibles. Un modelo con demasiados constructos, múltiples mediaciones, varias moderaciones y gran número de indicadores puede exigir una muestra, tiempo y capacidad analítica que excedan las condiciones reales del estudio. Por ello, el sistema conceptual debe equilibrar ambición y viabilidad. La pregunta clave es: **¿este modelo puede estimarse con los datos que realmente se podrán obtener?** Si la respuesta es dudosa, conviene simplificar. Simplificar no significa empobrecer el estudio; significa hacerlo defendible. Un sistema conceptual viable permite recolectar datos adecuados, formular hipótesis claras y avanzar hacia el análisis sin forzar la estructura. Para investigadores, esta enseñanza es esencial: un modelo pequeño pero coherente suele ser más valioso que un modelo amplio pero inestable. La viabilidad debe evaluarse antes de llegar al software. Además, las buenas prácticas recientes insisten en evitar el uso acrítico de SEM para justificar modelos excesivamente complejos. La técnica puede manejar complejidad, pero la complejidad debe ser necesaria. Un sistema viable no es el que incluye todo, sino el que incluye lo indispensable para responder el problema (Guenther et al., 2023).

La orientación hacia hipótesis. El sistema conceptual debe preparar la formulación de hipótesis, pero no debe confundirse con una lista apresurada de relaciones. Las hipótesis deben surgir de la lógica del problema. Si el sistema conceptual identifica capacidades digitales como antecedente del desempeño innovador, la hipótesis deberá expresar esa relación de manera clara. Si identifica aprendizaje organizacional como mediador, la hipótesis deberá formular un efecto

indirecto. Si identifica turbulencia ambiental como moderador, la hipótesis deberá explicar cómo cambia la relación principal. Esta progresión permite que las hipótesis no sean frases aisladas, sino respuestas tentativas a la pregunta de investigación. En SEM, las hipótesis serán después evaluadas mediante relaciones estructurales, pero su fuerza depende de su coherencia conceptual. Por ello, el capítulo 2 debe enseñar al investigador a construir hipótesis desde el sistema conceptual y no desde el deseo de obtener resultados significativos. Una hipótesis no debe ser escrita para que el software la pruebe; debe ser formulada porque el problema la necesita. La hipótesis es una proposición lógica antes de ser una ruta estadística. Esta distinción protege al investigador de transformar el modelo en un ejercicio de prueba mecánica (Gefen et al., 2000).

La representación gráfica preliminar. Una vez identificados problema, variable central, antecedentes, mediadores y moderadores, el investigador puede construir un primer diagrama conceptual. Este diagrama no es todavía el modelo final en SmartPLS, sino una herramienta de pensamiento. Permite observar si el sistema es coherente, si las relaciones están bien dirigidas y si existen variables sobrantes. El diagrama ayuda a detectar problemas que en texto pueden pasar desapercibidos: flechas innecesarias, constructos aislados, relaciones circulares o saturación conceptual. Además, facilita explicar el modelo a lectores, asesores o investigadors. Un buen diagrama preliminar debe ser simple, legible y alineado con la pregunta estructural. Si el investigador no puede explicar cada flecha, entonces el sistema conceptual todavía no está listo. Esta representación gráfica se desarrollará con mayor profundidad en capítulos posteriores, pero aquí cumple una función inicial: convertir el problema en una estructura visual defendible. En SEM, los diagramas suelen ser atractivos por su claridad visual, pero esa claridad no debe ocultar debilidad conceptual. Cada flecha debe representar una hipótesis o relación justificada; cada constructo debe tener una función dentro del sistema (Hair et al., 2021).

En conclusión, pasar del **problema de investigación** al **sistema conceptual** significa convertir una tensión científica en una arquitectura ordenada de variables, constructos y relaciones. Este proceso exige identificar una variable central, seleccionar antecedentes pertinentes, definir posibles mecanismos, delimitar condiciones contextuales, precisar unidad de análisis y anticipar la medición sin agotarla. El sistema conceptual es el primer mapa del modelo; no contiene todavía todos los detalles técnicos, pero establece la lógica que hará posible el análisis estructural. Para el investigador, este tema es decisivo porque le enseña que SEM no consiste en dibujar flechas ni correr software, sino en construir relaciones con sentido. Un buen sistema conceptual debe ser **claro, parsimonioso, viable, medible y coherente con el problema**. Solo cuando estas condiciones se cumplen, el investigador puede avanzar hacia la teoría, las variables, los constructos y el modelo estructural con mayor seguridad metodológica. Esta visión también protege contra el uso superficial del SEM: la técnica no debe justificar el modelo; el modelo debe justificar la técnica. Así, el capítulo fortalece la ruta metodológica del libro y prepara el avance hacia los temas posteriores sin agotar prematuramente los índices técnicos (Guenther et al., 2023).

Tipos de vacío: teórico, empírico, metodológico y práctico

El **vacío de investigación** es la razón académica que justifica pasar de un problema general a un **sistema conceptual**. No basta con afirmar que un tema es importante o actual; es necesario demostrar qué falta comprender, explicar, predecir, medir o contextualizar. En ciencias de la administración, muchos investigadors inician con fenómenos amplios como innovación, liderazgo, transformación digital, desempeño o sostenibilidad, pero todavía deben identificar cuál es la **brecha específica de conocimiento** que hace necesaria la investigación. El vacío puede aparecer cuando una relación entre variables no ha sido suficientemente estudiada, cuando los resultados previos son inconsistentes, cuando un fenómeno ha sido investigado en otros contextos pero no en el propio, cuando los constructos no han sido medidos adecuadamente o cuando una problemática práctica carece de explicación conceptual. Esta identificación es decisiva porque orienta la selección de variables, la formulación de hipótesis y la construcción del modelo SEM. Sin vacío, el modelo se vuelve una combinación de conceptos atractivos; con vacío, el modelo adquiere propósito, dirección y pertinencia. Por ello, reconocer el tipo de vacío permite construir una investigación más clara, defendible y metodológicamente coherente (Gefen et al., 2000).

El **vacío teórico** aparece cuando la literatura no explica suficientemente una relación, un mecanismo o una condición dentro de un fenómeno. Este tipo de vacío no se limita a decir que “hay pocos estudios”, sino que señala una insuficiencia conceptual: falta una explicación, una integración teórica o una conexión clara entre constructos. Por ejemplo, puede existir amplia literatura sobre capacidades digitales y desempeño, pero poca claridad sobre cómo esas capacidades se transforman en desempeño innovador mediante aprendizaje organizacional. En ese caso, el vacío no está en la existencia del tema, sino en el **mecanismo explicativo** que conecta las variables. En SEM, este vacío suele traducirse en hipótesis directas, mediaciones o moderaciones. Su importancia radica en que permite justificar por qué ciertos constructos deben relacionarse dentro del modelo. Un vacío teórico bien formulado evita que las flechas del modelo sean arbitrarias. Cada relación debe responder a una ausencia de explicación o a una necesidad de integración conceptual. Así, el vacío teórico convierte el problema en una oportunidad para fortalecer la lógica del modelo y no solo para repetir estudios previos (Hair et al., 2021).

El **vacío empírico** surge cuando existe poca evidencia sobre un fenómeno, relación o modelo en un contexto determinado. No necesariamente implica que el tema no haya sido estudiado; puede significar que ha sido analizado en otros países, sectores, tipos de organización o poblaciones, pero no en el contexto de interés. Por ejemplo, una relación entre transformación digital e innovación puede haber sido investigada en grandes empresas tecnológicas, pero no en pymes de servicios, empresas familiares, organizaciones públicas o economías emergentes. En ese caso, el vacío empírico permite justificar la necesidad de probar si una relación se comporta de manera similar

o diferente en un escenario específico. Este tipo de vacío es especialmente relevante en administración porque los fenómenos organizacionales dependen del contexto. No todas las relaciones son universales ni se expresan con la misma intensidad en todos los entornos. Sin embargo, el vacío empírico debe formularse con cuidado: no basta con decir “no hay estudios en mi ciudad” si el contexto no aporta valor conceptual. La evidencia faltante debe tener sentido para explicar o predecir mejor el fenómeno estudiado (Shmueli, 2010).

El **vacío metodológico** aparece cuando las formas disponibles de estudiar un fenómeno son insuficientes, limitadas o poco adecuadas. Puede relacionarse con escalas mal adaptadas, constructos mal especificados, uso inadecuado de técnicas SEM, ausencia de análisis predictivo, falta de evaluación del modelo de medición o confusión entre modelos reflectivos y formativos. En investigación administrativa, este vacío es frecuente cuando los estudios usan SEM de manera mecánica, sin justificar adecuadamente la técnica, sin reportar criterios esenciales o sin alinear propósito, constructos e indicadores. Un vacío metodológico no significa complicar el estudio innecesariamente, sino mejorar la forma en que se representa y analiza el fenómeno. Por ejemplo, si una variable ha sido tratada como reflectiva cuando conceptualmente funciona como formativa, existe una oportunidad metodológica. Si un estudio reporta relaciones estructurales sin cuidar la calidad de medición, también se abre un vacío. Este tipo de vacío es útil porque conecta el problema conceptual con la calidad del diseño empírico. Para el investigador, identificarlo implica comprender que la metodología no es un trámite técnico, sino una parte esencial de la contribución científica (Guenther et al., 2023).

El **vacío práctico** se refiere a una necesidad real de las organizaciones, mercados o instituciones que aún no cuenta con una explicación suficientemente útil para la toma de decisiones. En administración, muchas investigaciones nacen de problemas como baja innovación, resistencia al cambio, escasa adopción tecnológica, pérdida de clientes, baja productividad o limitada competitividad. Sin embargo, un vacío práctico no debe quedarse como diagnóstico empresarial. Para convertirse en investigación, debe traducirse en una pregunta conceptual: qué factores explican esa situación, qué variables permiten comprenderla, qué relaciones podrían anticiparla o qué condiciones la modifican. Por ejemplo, observar que las pymes tienen dificultades para digitalizarse es un punto de partida práctico; convertirlo en investigación requiere preguntar qué capacidades, recursos, aprendizajes o barreras explican esa dificultad. El vacío práctico fortalece la relevancia del estudio porque conecta el modelo con una necesidad administrativa concreta. No obstante, debe articularse con teoría y método para evitar que el trabajo sea solo descriptivo. Su valor está en mostrar que el modelo no solo responde a la literatura, sino también a una problemática relevante para la gestión (Gefen et al., 2000).

Los cuatro vacíos meniconados, no deben verse como categorías aisladas, sino como dimensiones que pueden combinarse dentro de una misma investigación. Un estudio puede tener simultáneamente un **vacío teórico**, porque no se comprende bien un mecanismo; un **vacío empírico**, porque falta evidencia en cierto contexto; un **vacío**

metodológico, porque la medición previa ha sido limitada; y un **vacío práctico**, porque el fenómeno afecta la toma de decisiones organizacionales. Sin embargo, no todos deben tener el mismo peso. **El investigador debe identificar cuál es el vacío principal y cuáles funcionan como apoyo**. Esta jerarquía evita que la justificación del estudio se vuelva dispersa. Por ejemplo, si el objetivo central es explicar cómo las capacidades digitales influyen en el desempeño innovador mediante aprendizaje organizacional, el vacío principal puede ser teórico; si además se estudian pymes mexicanas, aparece un vacío empírico contextual; si se cuida la especificación de constructos, puede añadirse un componente metodológico. La clave es que los vacíos estén articulados y no acumulados. Un modelo sólido no necesita declarar todos los vacíos posibles, sino justificar con precisión el vacío que realmente sostiene la investigación (Hair et al., 2021).

El vacío seleccionado debe orientar la pregunta de investigación. Si el vacío es teórico, la pregunta deberá enfocarse en explicar una relación o mecanismo. Si el vacío es empírico, deberá resaltar el contexto y la necesidad de evidencia específica. Si el vacío es metodológico, deberá atender la forma de medición, especificación o evaluación del modelo. Si el vacío es práctico, deberá vincular el fenómeno con una necesidad administrativa concreta. Esta correspondencia es fundamental porque evita incoherencias entre justificación, pregunta, objetivos e hipótesis. Por ejemplo, no sería consistente afirmar que el vacío principal es predictivo y luego formular una pregunta puramente explicativa; tampoco sería coherente declarar un vacío metodológico y después no cuidar la especificación del modelo. La pregunta debe ser la consecuencia lógica del vacío identificado. En SEM, esta alineación es especialmente importante porque el modelo se construye a partir de relaciones justificadas. El vacío define qué falta conocer; la pregunta define qué se responderá; el sistema conceptual define cómo se organizarán las variables para responderlo. Sin esta secuencia, el modelo pierde dirección y puede convertirse en una estructura técnicamente estimable, pero conceptualmente débil (Shmueli, 2010).

El vacío también orienta la selección de variables y constructos. Si el vacío se refiere a una relación no explicada, el investigador debe seleccionar variables que permitan comprender esa relación. Si el vacío se refiere a un mecanismo ausente, puede incorporarse una mediación. Si el vacío se refiere a condiciones contextuales, puede plantearse una moderación. Si el vacío es metodológico, será necesario revisar cómo se define y mide cada constructo. Esta lógica evita el uso de variables por moda o conveniencia. Cada variable debe responder al vacío identificado. Por ejemplo, si el vacío consiste en explicar por qué la transformación digital no siempre mejora el desempeño innovador, podría ser pertinente incorporar aprendizaje organizacional como mecanismo. Si el vacío consiste en entender por qué el efecto varía entre empresas, podría considerarse turbulencia ambiental o madurez digital como condición. Así, el vacío no solo justifica el estudio, sino que estructura el modelo. En términos pedagógicos, el investigador debe aprender que las variables no se agregan porque “aparecen en la literatura”, sino porque ayudan a responder un vacío específico dentro del problema de investigación (Guenther et al., 2023).

Una forma práctica de formular el vacío consiste en construir una frase con cuatro componentes: lo que se sabe, **lo que no se sabe**, **dónde ocurre la limitación y por qué importa**. Por ejemplo: “Aunque la literatura ha estudiado la transformación digital en empresas, aún no se comprende suficientemente cómo las capacidades digitales se relacionan con el desempeño innovador en pymes de servicios, lo cual limita la explicación de los mecanismos que permiten convertir recursos digitales en resultados organizacionales”. Esta estructura ayuda a evitar vacíos vagos o genéricos. También permite conectar el vacío con la pregunta estructural y con el sistema conceptual. Si el investigador puede escribir el vacío en una frase clara, será más fácil derivar objetivos, hipótesis y constructos. En cambio, si el vacío se expresa como una afirmación amplia —“hay pocos estudios sobre innovación”—, todavía no existe una justificación suficiente para modelar relaciones. El vacío debe ser específico, argumentado y modelable. Su función no es adornar la introducción, sino construir la base lógica del modelo SEM (Gefen et al., 2000).

El vacío debe ser proporcional al alcance del estudio. Un error frecuente consiste en declarar vacíos demasiado ambiciosos, como si una tesis, artículo o capítulo pudiera resolver por completo una teoría amplia o una problemática organizacional compleja. La investigación debe ser relevante, pero también **viable y delimitada**. Un vacío bien planteado no promete explicarlo todo; identifica una porción específica del fenómeno que puede estudiarse con rigor. Por ejemplo, en lugar de afirmar que se resolverá el problema de la transformación digital en las pymes, puede señalarse que se analizará la relación entre capacidades digitales, aprendizaje organizacional y desempeño innovador en un contexto determinado. Esta delimitación no reduce la contribución; la hace defendible. Además, permite construir modelos más parsimoniosos. En SEM, un vacío demasiado amplio suele generar modelos excesivamente grandes, con muchas variables y baja claridad interpretativa. Por ello, el vacío debe corresponder al tamaño del modelo, a la disponibilidad de datos, al propósito investigativo y a la capacidad de medición. La contribución científica no depende de prometer demasiado, sino de responder con precisión algo que realmente faltaba comprender (Hair et al., 2021).

También es importante evitar los falsos vacíos. Un falso vacío aparece cuando el investigador justifica su estudio con argumentos débiles, como “no se ha estudiado en mi ciudad”, “hay pocos artículos recientes” o “no se ha aplicado exactamente este modelo”, sin demostrar por qué esa ausencia es relevante. No toda falta de estudios constituye automáticamente una brecha científica. Para que exista vacío, la ausencia debe afectar la comprensión, explicación, predicción, medición o aplicación del fenómeno. Por ejemplo, si un modelo ya ha sido probado ampliamente en contextos muy similares, repetirlo sin adaptación ni contribución puede tener bajo valor. En cambio, si el nuevo contexto presenta condiciones distintas que podrían modificar las relaciones, entonces sí puede existir un vacío empírico válido. Del mismo modo, usar una técnica diferente no constituye por sí solo una contribución metodológica si no mejora la comprensión del fenómeno. El investigador debe aprender a justificar por qué el vacío importa. Esto fortalece la honestidad académica del trabajo y evita construir modelos sobre justificaciones superficiales (Shmueli, 2010).

El vacío metodológico debe manejarse con especial cuidado. En este tema solo interesa comprender que algunas investigaciones son necesarias porque los estudios previos han medido de forma limitada, han especificado mal constructos, han confundido propósitos explicativos y predictivos o han reportado SEM de manera incompleta. Lo importante es que el investigador entienda que **los vacíos metodológicos existen cuando la forma de estudiar el fenómeno afecta la calidad de las conclusiones.** Por ejemplo, si un constructo es ambiguo, si los indicadores no representan adecuadamente el concepto o si el modelo no corresponde al propósito declarado, el problema no es solo técnico, sino conceptual. Esta comprensión prepara el terreno para capítulos posteriores sin agotarlos. La progresión debe ser creciente: primero se identifica el vacío; después se construye el sistema conceptual; más adelante se profundiza en constructos, indicadores y evaluación del modelo (Guenther et al., 2023).

La identificación del vacío también ayuda a definir la contribución esperada. Un estudio con vacío teórico puede contribuir al explicar una relación o mecanismo. Un estudio con vacío empírico puede contribuir al aportar evidencia en un contexto poco estudiado. Un estudio con vacío metodológico puede contribuir al mejorar la medición, especificación o evaluación de un modelo. Un estudio con vacío práctico puede contribuir al orientar decisiones organizacionales. Esta contribución debe formularse con prudencia. **No siempre es necesario crear una teoría nueva; en muchos casos, la contribución consiste en aclarar una relación, adaptar un modelo a un contexto, probar un mecanismo o mejorar la coherencia metodológica.** Lo importante es que la contribución responda directamente al vacío. Si el vacío y la contribución no coinciden, el estudio pierde consistencia. Por ejemplo, si el vacío declarado es metodológico, la contribución no puede limitarse a resultados descriptivos; si el vacío es práctico, la discusión debe mostrar implicaciones para la gestión. En SEM, esta correspondencia entre vacío, modelo y contribución fortalece la defensa académica del trabajo (Gefen et al., 2000).

El vacío debe traducirse en una ruta de modelación. Esta ruta no es todavía el análisis estadístico, sino la lógica que permitirá pasar del problema al sistema conceptual. Un vacío teórico puede conducir a relaciones directas o mediadas; un vacío empírico puede justificar probar un modelo en un contexto específico; un vacío metodológico puede orientar la especificación de constructos; un vacío práctico puede ayudar a seleccionar una variable dependiente relevante. Por ejemplo, si el vacío es que no se comprende cómo las capacidades digitales generan innovación, la ruta puede incluir capacidades digitales como antecedente, aprendizaje organizacional como mecanismo y desempeño innovador como resultado. Si el vacío es que no se sabe bajo qué condiciones esa relación se fortalece, puede incorporarse una variable moderadora. Así, el vacío se convierte en arquitectura conceptual. Esta transformación es central para el capítulo 2: no basta con identificar qué falta; hay que mostrar cómo esa ausencia se convierte en un sistema de relaciones analizables. El vacío, por tanto, funciona como el motor del modelo (Hair et al., 2021).

En conclusión, los **vacíos teórico, empírico, metodológico y práctico** son herramientas para justificar y orientar la investigación, no simples etiquetas. El vacío teórico permite fortalecer la explicación; el empírico delimita la necesidad de evidencia contextual; el metodológico mejora la forma de estudiar el fenómeno, y el práctico conecta la investigación con necesidades reales de la administración. **La calidad del estudio depende de identificar un vacío principal, articularlo con otros vacíos secundarios y traducirlo en pregunta, objetivos, variables e hipótesis.** En SEM, esta etapa es decisiva porque el modelo no debe construirse por acumulación de variables, sino como respuesta organizada a una brecha de conocimiento. Para mantener la progresión del libro, este tema introduce los vacíos como base del sistema conceptual, sin agotar todavía los criterios técnicos de medición o evaluación estructural. Así, el investigador aprende que un modelo sólido no nace del software, sino de una justificación clara sobre qué falta conocer y por qué vale la pena investigarlo (Shmueli, 2010).

Explicación, predicción y lógica del modelo

La construcción del **sistema conceptual** exige definir si el estudio busca **explicar**, **predecir** o integrar ambos propósitos de manera justificada. Esta decisión es central porque no todas las investigaciones estructurales persiguen el mismo tipo de conocimiento. Un modelo explicativo intenta comprender por qué ocurre un fenómeno, qué relaciones lo sostienen y qué mecanismos permiten interpretarlo. En cambio, un modelo predictivo busca anticipar el comportamiento de una variable resultado con base en sus antecedentes. En ciencias de la administración, esta diferencia es especialmente importante porque muchos estudios declaran explicar relaciones organizacionales, pero en realidad evalúan capacidad predictiva, mientras otros reportan resultados estadísticos sin aclarar qué tipo de contribución ofrecen. Por ello, antes de seleccionar variables, hipótesis o técnica SEM, **el investigador debe definir con claridad el propósito de su modelo**. La lógica del modelo no se construye solo con flechas, sino con una decisión metodológica previa sobre el tipo de evidencia que se desea producir. Si el objetivo es explicar, la teoría y la coherencia causal conceptual adquieren mayor peso; si el objetivo es predecir, la capacidad anticipatoria del modelo se vuelve prioritaria. Esta distinción evita confundir significancia estadística con comprensión del fenómeno o varianza explicada con utilidad predictiva (Shmueli, 2010).

Un modelo orientado a la explicación parte de una pregunta de tipo "por qué" o "cómo". Su finalidad es comprender las razones por las cuales una variable influye en otra dentro de un fenómeno administrativo. Por ejemplo, un investigador puede preguntarse por qué las capacidades digitales favorecen el desempeño innovador, cómo el liderazgo transformacional impulsa el aprendizaje organizacional o por qué la confianza incrementa la intención de adopción tecnológica. En este tipo de modelo, las relaciones deben estar conceptualmente justificadas antes de ser estimadas. No basta con que dos variables estén asociadas; debe existir una argumentación que explique la dirección esperada de la relación. Por ello, la explicación estructural exige definir

antecedentes, consecuencias, mecanismos y condiciones. Una flecha en un modelo SEM representa una hipótesis, no una ocurrencia gráfica. Cada relación debe responder a una necesidad teórica o conceptual derivada del problema de investigación. En este sentido, el modelo explicativo se apoya en la coherencia entre problema, pregunta estructural, objetivos, constructos e hipótesis. Su valor no reside únicamente en obtener coeficientes significativos, sino en mostrar que las relaciones propuestas ayudan a comprender mejor el fenómeno estudiado (Gefen et al., 2000).

Un modelo orientado a la predicción parte de una pregunta distinta: qué variables permiten anticipar mejor un resultado. En lugar de concentrarse principalmente en explicar por qué ocurre una relación, la predicción busca estimar qué tan bien el modelo puede anticipar valores de una variable dependiente. En administración, esto puede aplicarse a la intención de compra, la satisfacción, el desempeño innovador, la adopción tecnológica, la productividad, la lealtad del cliente o la rotación laboral. La lógica predictiva es útil cuando el investigador desea generar conocimiento aplicable para anticipar comportamientos, decisiones o resultados organizacionales. Sin embargo, predecir no equivale necesariamente a explicar. Un modelo puede tener buena capacidad predictiva sin ofrecer una teoría profunda del fenómeno; también puede tener una explicación teórica sólida, pero limitada capacidad para anticipar casos nuevos. Por ello, el investigador debe declarar desde el inicio si la predicción será el propósito central o complementario. Esta decisión afectará la selección de variables, el tipo de evaluación y la interpretación de resultados. En PLS-SEM, la orientación explicativa-predictiva suele ser una fortaleza, siempre que el modelo esté conceptualmente bien definido y no se use la técnica como sustituto de la teoría (Hair et al., 2021).

La distinción entre explicación y predicción no debe entenderse como una oposición absoluta, sino como una diferencia de énfasis. En muchas investigaciones de administración, el modelo puede tener un propósito mixto: explicar relaciones teóricas y, al mismo tiempo, evaluar si esas relaciones permiten anticipar un resultado relevante. Por ejemplo, un estudio puede explicar cómo las capacidades digitales influyen en el desempeño innovador mediante aprendizaje organizacional y, además, valorar si ese conjunto de variables permite predecir dicho desempeño. No obstante, combinar explicación y predicción exige coherencia. El investigador no debe declarar ambos propósitos si después solo evalúa uno. Si el estudio afirma tener orientación predictiva, debe incorporar criterios adecuados para valorar la capacidad de anticipación. Si afirma tener orientación explicativa, debe cuidar la teoría, la dirección de relaciones y la justificación de hipótesis. La combinación es válida cuando existe alineación entre pregunta, objetivos, modelo y evaluación. Sin esta alineación, el estudio puede caer en ambigüedad metodológica. La lógica del modelo debe indicar qué se desea comprender, qué se desea anticipar y qué evidencia se usará para sostener cada propósito (Guenther et al., 2023).

La lógica del modelo inicia con la identificación de una variable resultado. Esta variable representa el fenómeno que se desea explicar o predecir. Sin una variable resultado clara, el modelo pierde dirección y puede convertirse en una red de

relaciones sin jerarquía. En estudios de administración, la variable resultado puede ser desempeño organizacional, innovación, satisfacción, adopción tecnológica, lealtad, productividad, resiliencia, competitividad o sostenibilidad. La elección depende del problema y del vacío de investigación. Si el problema se refiere a la dificultad de las pymes para generar innovación, el desempeño innovador puede ocupar el centro del modelo. Si el problema se relaciona con la aceptación de una plataforma digital, la intención de uso puede ser la variable resultado. Definir esta variable permite organizar los antecedentes y establecer qué relaciones son necesarias. En un modelo explicativo, la variable resultado ayuda a construir una narrativa causal conceptual; en un modelo predictivo, permite concentrar la evaluación en la capacidad anticipatoria del sistema. Por ello, la lógica del modelo debe comenzar con una pregunta sencilla pero decisiva: **qué resultado administrativo se busca comprender o anticipar** (Gefen et al., 2000).

Después de definir la variable resultado, el investigador debe seleccionar los antecedentes conceptuales. Estos son factores que pueden influir en la variable dependiente o ayudar a anticiparla. La selección no debe responder a modas académicas ni a la disponibilidad inmediata de escalas, sino a la función que cada variable cumple dentro del modelo. En un modelo explicativo, los antecedentes deben tener sentido teórico: deben ayudar a responder por qué ocurre el fenómeno. En un modelo predictivo, además de sentido conceptual, deben aportar capacidad de anticipación. Por ejemplo, si se busca explicar el desempeño innovador, podrían considerarse capacidades digitales, aprendizaje organizacional, cultura innovadora o liderazgo tecnológico. Sin embargo, no todos estos factores deben incorporarse automáticamente. Cada variable debe justificar su presencia: qué aporta, cómo se diferencia de las demás y por qué resulta pertinente para la variable resultado. Esta revisión evita redundancia y sobrecarga del modelo. Una lógica estructural sólida exige parsimonia, es decir, incluir solo los elementos necesarios para responder la pregunta. Un modelo más grande no es necesariamente más fuerte; lo es aquel donde cada antecedente tiene una función clara (Hair et al., 2021).

La explicación requiere diferenciar entre relaciones directas y **mecanismos intermedios**. Una relación directa plantea que una variable antecedente influye sobre una variable resultado. Por ejemplo, las capacidades digitales pueden influir directamente en el desempeño innovador. Sin embargo, muchas veces la relación directa no explica completamente cómo ocurre el efecto. En ese caso, puede ser necesario incorporar un mecanismo, como el aprendizaje organizacional. La mediación permite comprender cómo una variable transmite el efecto de otra. Esta lógica resulta útil cuando el investigador no solo quiere saber si existe una relación, sino entender el proceso mediante el cual se produce. En administración, los mecanismos son importantes porque los fenómenos organizacionales rara vez ocurren de manera automática. Las tecnologías, los recursos o las capacidades no generan resultados por sí solos; suelen requerir procesos de aprendizaje, integración, coordinación o adaptación. Por ello, la lógica explicativa debe preguntarse si el modelo necesita mediadores. No obstante, la mediación debe estar justificada por el problema y por la teoría conceptual. Incluir mediadores solo para hacer el modelo más complejo puede

debilitar la claridad del estudio. La mediación debe aportar explicación, no ornamentación metodológica (Shmueli, 2010).

La predicción, por su parte, exige identificar variables con capacidad para anticipar variaciones en la variable resultado. Esta lógica no se limita a saber si una relación es estadísticamente significativa, sino a valorar si el conjunto de antecedentes permite estimar el resultado con utilidad. En este sentido, una variable puede ser conceptualmente interesante, pero aportar poca capacidad predictiva; otra puede no ser el centro de una teoría fuerte, pero mejorar la anticipación del resultado. Esta diferencia obliga al investigador a ser explícito sobre la función de cada variable dentro del modelo. En estudios orientados a PLS-SEM, el énfasis predictivo puede justificar la inclusión de variables que incrementen la capacidad de explicación de varianza y la relevancia predictiva, siempre que no contradigan la coherencia conceptual. La predicción no debe convertirse en acumulación indiscriminada de variables. Un modelo predictivo también necesita orden, parsimonia y justificación. La diferencia está en que su evaluación no se agota en la interpretación teórica de las relaciones, sino que considera la utilidad del modelo para anticipar el comportamiento de la variable dependiente. Por ello, la lógica predictiva debe estar presente desde el diseño, no añadirse al final (Guenther et al., 2023).

La lógica del modelo también debe considerar las condiciones contextuales que pueden modificar las relaciones. En ciencias de la administración, los efectos rara vez son uniformes en todos los escenarios. Una capacidad puede ser más valiosa en entornos turbulentos que en entornos estables; una estrategia puede funcionar mejor en empresas grandes que en microempresas; una herramienta digital puede tener mayor impacto cuando existe cultura organizacional favorable. Estas condiciones pueden incorporarse mediante moderaciones, siempre que estén justificadas. La moderación responde a preguntas como: **cuándo ocurre una relación, para quién es más fuerte o bajo qué circunstancias cambia su intensidad**. Esta lógica ayuda a refinar la explicación y también puede mejorar la predicción. Sin embargo, no toda variable contextual debe convertirse en moderadora. El investigador debe evitar incluir moderaciones solo para sofisticar el modelo. La condición moderadora debe derivarse del problema y aportar comprensión adicional. En una arquitectura conceptual bien formulada, las moderaciones no son adornos; son elementos que explican variaciones en las relaciones estructurales. Su inclusión debe aumentar claridad, no confusión (Gefen et al., 2000).

La lógica explicativa y predictiva debe mantenerse alineada con el nivel de análisis. No es metodológicamente consistente explicar resultados organizacionales con datos individuales si no se justifica la correspondencia entre niveles. Tampoco es adecuado predecir desempeño empresarial únicamente con percepciones de empleados si el constructo se define como resultado organizacional objetivo. Por ello, el investigador debe establecer si el modelo opera a nivel individual, grupal, organizacional, interorganizacional o contextual. Esta decisión afecta la definición de variables, la selección de informantes, el instrumento y la interpretación de resultados. Por ejemplo, un modelo sobre intención de uso puede medirse a nivel individual; un

modelo sobre capacidades digitales organizacionales requiere informantes que representen adecuadamente a la empresa o datos agregados. La lógica del modelo no solo conecta variables, también conecta niveles de realidad. Si esa conexión no está clara, la interpretación puede ser incorrecta. En SEM, la coherencia entre unidad de análisis, constructos e indicadores es una condición previa para que las relaciones tengan sentido. El modelo debe explicar o predecir dentro del nivel para el cual fue diseñado (Hair et al., 2021).

La diferencia entre explicar y predecir también afecta la redacción de hipótesis. En una lógica explicativa, la hipótesis debe expresar una relación teóricamente esperada: por ejemplo, “las capacidades digitales influyen positivamente en el desempeño innovador”. Esta hipótesis requiere fundamento conceptual. En una lógica predictiva, la hipótesis puede orientarse a señalar que cierto conjunto de variables mejora la anticipación de un resultado. Sin embargo, incluso en modelos predictivos, las hipótesis deben ser interpretables y coherentes. No basta con incluir variables porque podrían mejorar un indicador estadístico. La redacción de hipótesis debe reflejar la lógica del modelo. Si hay mediación, la hipótesis debe indicar el mecanismo. Si hay moderación, debe indicar la condición. Si hay predicción, debe explicitar la variable resultado y los antecedentes relevantes. Una hipótesis mal redactada puede generar confusión en la estimación y en la discusión. Por ello, antes de ejecutar cualquier análisis, el investigador debe revisar si las hipótesis responden verdaderamente a la pregunta estructural y si distinguen el propósito explicativo o predictivo del estudio. La hipótesis es una proposición conceptual antes de ser una ruta estadística (Shmueli, 2010).

La lógica del modelo debe evitar el uso mecánico del SEM la cual es una técnica útil para modelos complejos, explicación de varianza y propósitos predictivos, su uso debe estar justificado por la naturaleza del problema y del modelo. No debe elegirse únicamente porque es accesible, porque permite trabajar con muestras moderadas o porque el software es amigable. Una investigación rigurosa debe explicar por qué la técnica corresponde a la pregunta, al tipo de constructos, al propósito y a los datos disponibles. **La lógica del modelo precede a la técnica.** Si el estudio requiere confirmación estricta de una teoría consolidada y evaluación de ajuste global, quizá otra técnica sea más apropiada. **Si el estudio busca explicación-predicción con constructos latentes y un modelo complejo, SEM puede ser pertinente.** Lo importante es que la elección metodológica no sea automática. En este capítulo, la discusión no debe agotarse técnicamente; basta con que el investigador comprenda que la técnica debe ser consecuencia del propósito investigativo. La calidad del modelo no depende solo del software, sino de la coherencia conceptual que lo sostiene (Guenther et al., 2023).

Una buena lógica de modelo exige parsimonia estructural. La parsimonia significa que el modelo debe contener los elementos suficientes para explicar o predecir el fenómeno sin añadir variables innecesarias. En investigación administrativa, es común que el investigador quiera incorporar todos los factores encontrados en la literatura. Sin embargo, un modelo sobrecargado puede perder

claridad, aumentar redundancia conceptual y dificultar la interpretación. **La parsimonia no significa simplificar en exceso, sino seleccionar con criterio**. Cada constructo debe tener una función: antecedente, resultado, mediador, moderador o control. **Si una variable no cumple una función clara, debe reconsiderarse**. Esta decisión es especialmente importante para principiantes, porque modelos más grandes suelen parecer más sofisticados, pero no necesariamente son más sólidos. **Un modelo parsimonioso permite defender mejor las hipótesis, seleccionar indicadores pertinentes y evitar problemas posteriores**. Además, favorece la lectura pedagógica del sistema conceptual. El investigador debe aprender a construir modelos que respondan al problema, no modelos que intenten abarcar todo. La lógica del modelo se fortalece cuando cada elemento tiene un lugar y una razón de existir (Gefen et al., 2000).

El modelo también debe ser viable empíricamente. Un sistema conceptual puede parecer atractivo, pero si no puede medirse, estimarse o interpretarse con los datos disponibles, pierde fuerza metodológica. La viabilidad depende del acceso a la población, la claridad de los indicadores, el tamaño de muestra, la complejidad del modelo y la capacidad de recolectar datos adecuados. En un modelo explicativo, la viabilidad implica contar con información suficiente para evaluar relaciones teóricas. En un modelo predictivo, implica contar con datos que permitan valorar la capacidad anticipatoria del modelo. Un diseño excesivamente complejo puede requerir una muestra que el investigador no podrá alcanzar. Por ello, la lógica del modelo debe equilibrar ambición y posibilidad real de ejecución. Simplificar no significa reducir calidad; puede significar aumentar rigor. Un modelo viable es aquel que puede defenderse conceptualmente y evaluarse empíricamente con estabilidad. En este capítulo, la viabilidad se aborda como criterio de diseño, no como cálculo técnico exhaustivo. Su función es advertir que la calidad del modelo se decide antes del software (Hair et al., 2021).

La lógica del modelo debe ser coherente con el tipo de contribución esperada. Si el estudio busca explicación, la contribución puede consistir en aclarar una relación, proponer un mecanismo o integrar constructos de manera novedosa. Si busca predicción, la contribución puede consistir en identificar antecedentes útiles para anticipar un resultado administrativo. Si combina ambos propósitos, debe mostrar cómo la explicación conceptual y la capacidad predictiva se complementan. Esta claridad evita conclusiones excesivas. Por ejemplo, un modelo con alta varianza explicada no necesariamente resuelve una teoría; un modelo con relaciones significativas no necesariamente predice bien. **La contribución debe corresponder al propósito**. En administración, esta precisión es importante porque los resultados suelen traducirse en recomendaciones para organizaciones. **Si el modelo explica, las recomendaciones deben apoyarse en la lógica de relaciones; si predice, deben orientarse a anticipar y monitorear factores clave**. La contribución no debe formularse al final como una ocurrencia, sino estar presente desde el diseño del modelo. Un modelo coherente permite discutir resultados con prudencia, claridad y utilidad académica (Shmueli, 2010).

En conclusión, el tema **explicación, predicción y lógica del modelo** permite comprender que SEM no es simplemente una técnica para estimar relaciones, sino una forma de organizar el pensamiento investigativo. La explicación busca comprender por qué ocurre un fenómeno; la predicción busca anticipar resultados; y la lógica del modelo conecta ambas posibilidades mediante variables, constructos, relaciones, mecanismos y condiciones. Para que el modelo sea defendible, debe tener una variable resultado clara, antecedentes pertinentes, hipótesis coherentes, unidad de análisis definida, contexto delimitado y viabilidad empírica. Además, debe evitar el uso mecánico de PLS-SEM y sostener la elección técnica con base en el propósito investigativo. Este tema prepara el avance hacia las relaciones conceptuales del siguiente apartado sin agotar todavía los criterios técnicos de medición o evaluación estructural. El lector debe conservar una idea central: **explicar y predecir son propósitos relacionados, pero no equivalentes**. Distinguirlos desde el sistema conceptual permite construir modelos más claros, más útiles y metodológicamente más responsables (Guenther et al., 2023).

Relaciones conceptuales: antecedentes, consecuencias y mecanismos

Las **relaciones conceptuales** constituyen el núcleo del sistema conceptual, porque permiten transformar un problema de investigación en una estructura lógica de variables y constructos. Después de identificar el vacío de conocimiento y distinguir si el modelo busca explicar, predecir o combinar ambos propósitos, el investigador debe definir cómo se relacionan los elementos del fenómeno. En esta etapa, no se trata todavía de estimar coeficientes ni de interpretar resultados estadísticos, sino de construir una **red conceptual defendible**. Una relación conceptual debe responder a una pregunta básica: ¿por qué un constructo debería estar vinculado con otro? En SEM, cada flecha futura del modelo debe tener sentido antes de ser estimada. Por ello, las relaciones no deben incorporarse por intuición, moda académica o simple disponibilidad de escalas. Deben surgir del problema, del vacío identificado, del propósito investigativo y de la lógica del fenómeno. En ciencias de la administración, estas relaciones suelen organizarse mediante **antecedentes**, **consecuencias** y **mecanismos**, tres categorías que ayudan a ordenar el modelo y evitar la acumulación descontrolada de variables. Esta organización permite que el sistema conceptual sea claro, parsimonioso y metodológicamente defendible (Gefen et al., 2000).

Los **antecedentes** son variables o constructos que se ubican antes de la variable central y ayudan a explicarla o predecirla. Su función consiste en responder qué factores pueden influir en el fenómeno de interés. Por ejemplo, si la variable central es el desempeño innovador, los antecedentes podrían ser capacidades digitales, orientación al mercado, aprendizaje organizacional o cultura innovadora, siempre que exista una justificación conceptual para incluirlos. Un error frecuente consiste en seleccionar antecedentes porque aparecen repetidamente en la literatura, sin analizar si realmente corresponden al problema específico. La presencia de un antecedente debe justificarse por su función dentro del modelo: qué aporta, cómo se diferencia de

otros factores y por qué se espera que influya en la variable resultado. En SEM, la selección de antecedentes es especialmente importante porque estos contribuyen a explicar varianza en las variables endógenas, pero una mayor cantidad de antecedentes no garantiza un mejor modelo. La calidad depende de la pertinencia de las relaciones, no de su número. Por ello, los antecedentes deben elegirse con **parsimonia conceptual**, evitando redundancia, solapamiento y relaciones débiles. Un buen antecedente no solo aparece antes en el diagrama; aporta sentido a la explicación o predicción del fenómeno (Hair et al., 2021).

Las **consecuencias** son los resultados que el modelo busca explicar, anticipar o comprender. En muchos modelos SEM, la consecuencia principal coincide con la variable dependiente o variable central. Puede tratarse de desempeño organizacional, innovación, intención de adopción, satisfacción, lealtad, competitividad, productividad, resiliencia o sostenibilidad. La consecuencia otorga dirección al sistema conceptual porque permite ordenar los antecedentes y mecanismos alrededor de un resultado. Sin una consecuencia clara, el modelo puede convertirse en una red dispersa donde las variables se relacionan sin jerarquía. La elección de la consecuencia debe responder al vacío de investigación. Si el problema se refiere a la baja adopción tecnológica, la consecuencia podría ser intención de uso o uso efectivo. Si se refiere a la dificultad para innovar, la consecuencia podría ser desempeño innovador. Además, la consecuencia debe ser coherente con el propósito del estudio: en una lógica explicativa, interesa comprender por qué ocurre; en una lógica predictiva, interesa anticiparla con precisión. Esta distinción evita confundir una relación significativa con verdadera capacidad predictiva. Por tanto, la consecuencia no es solo un resultado final del modelo; es el eje que define la lógica de construcción, evaluación e interpretación del sistema conceptual (Shmueli, 2010).

Los **mecanismos** explican cómo o por qué un antecedente se relaciona con una consecuencia. En términos conceptuales, un mecanismo permite abrir la “caja negra” entre una variable explicativa y una variable resultado. Por ejemplo, las capacidades digitales pueden relacionarse con el desempeño innovador, pero ese vínculo puede explicarse mejor si se considera el aprendizaje organizacional como mecanismo intermedio. Del mismo modo, el liderazgo puede influir en el desempeño a través de la motivación, la confianza o la colaboración. En un sistema conceptual, los mecanismos suelen expresarse mediante variables mediadoras. Su función no es aumentar la complejidad del modelo, sino mejorar la comprensión del proceso que conecta antecedentes y consecuencias. Incluir mecanismos sin fundamento puede debilitar el modelo, porque añade relaciones difíciles de defender. Por ello, el mecanismo debe derivarse del problema y del vacío identificado. Si el vacío es teórico, el mecanismo puede ayudar a explicar una relación insuficientemente comprendida. Si el vacío es práctico, puede mostrar qué proceso organizacional debe fortalecerse para mejorar un resultado. Un buen mecanismo transforma una relación simple en una explicación más rica, siempre que su inclusión sea conceptualmente necesaria y metodológicamente viable (Guenther et al., 2023).

La primera tarea al construir relaciones conceptuales consiste en diferenciar entre una **relación directa** y una **relación indirecta**. Una relación directa plantea que un antecedente se vincula con una consecuencia sin incluir una variable intermedia. Por ejemplo, la orientación al mercado puede relacionarse directamente con el desempeño comercial. Una relación indirecta, en cambio, propone que el efecto ocurre mediante un mecanismo. Por ejemplo, la orientación al mercado puede mejorar el desempeño comercial mediante la capacidad de respuesta al cliente. Esta distinción es importante porque modifica la lógica del modelo y la forma de formular hipótesis. La relación directa es útil cuando el problema requiere evaluar un vínculo principal. La relación indirecta es útil cuando el problema exige comprender el proceso que explica ese vínculo. En SEM, ambas relaciones pueden coexistir, pero no deben agregarse de manera automática. El investigador debe justificar si espera un efecto directo, un efecto indirecto o ambos. Esta decisión evita modelos inflados y mejora la claridad teórica. Las relaciones deben responder a la arquitectura conceptual y no al deseo de obtener más resultados. Una relación directa sin fundamento es débil; una relación indirecta sin mecanismo claro es innecesaria (Gefen et al., 2000).

La mediación representa una de las formas más importantes de mecanismo conceptual. Una variable mediadora se ubica entre un antecedente y una consecuencia, explicando cómo se transmite el efecto. Por ejemplo, si las capacidades digitales influyen en el desempeño innovador mediante aprendizaje organizacional, el aprendizaje funciona como mediador. Esta estructura permite comprender que la tecnología, por sí sola, no produce automáticamente resultados; se requiere un proceso de apropiación, aprendizaje o transformación organizacional. La mediación es especialmente útil cuando el investigador desea explicar procesos y no solo asociaciones. No obstante, debe estar cuidadosamente justificada. Una mediación exige que el mediador tenga sentido conceptual entre la variable antecedente y la consecuencia. También debe evitarse incluir varios mediadores sin una lógica clara, porque esto puede hacer que el modelo sea difícil de interpretar. En estudios con SEM, la mediación puede enriquecer la explicación del modelo, pero su valor depende de la coherencia del sistema conceptual. Antes de analizar efectos indirectos, el investigador debe poder explicar verbalmente por qué el mediador está ahí. Si no puede hacerlo, la mediación no debe incorporarse. La mediación debe ser una necesidad explicativa, no un adorno estadístico (Hair et al., 2021).

La **moderación** cumple una función distinta. **Mientras la mediación responde al cómo o por qué ocurre una relación, la moderación responde al cuándo, para quién o bajo qué condiciones esa relación cambi**a. Una variable moderadora modifica la intensidad o dirección del vínculo entre un antecedente y una consecuencia. Por ejemplo, la turbulencia ambiental puede fortalecer la relación entre capacidades digitales y desempeño innovador; el tamaño de empresa puede alterar la relación entre orientación al mercado y desempeño; el apoyo directivo puede modificar la relación entre tecnología e intención de uso. **La moderación es útil cuando el problema sugiere que una relación no opera igual en todos los contextos**. Sin embargo, debe usarse con prudencia. Incluir moderadores sin fundamento puede generar modelos complejos, difíciles de estimar y poco claros. La moderación debe

estar vinculada con una condición relevante del fenómeno. Además, debe ser coherente con la unidad de análisis y con la disponibilidad de datos. En una lógica predictiva, las moderaciones pueden mejorar la comprensión de diferencias entre escenarios; en una lógica explicativa, pueden precisar los límites de una relación. La clave es que la moderación aporte conocimiento y no solo complejidad (Shmueli, 2010).

Las relaciones conceptuales también pueden incluir efectos secuenciales, cuando un antecedente influye en una consecuencia mediante más de un paso intermedio. Por ejemplo, las capacidades digitales podrían fortalecer el aprendizaje organizacional, este aprendizaje podría favorecer la innovación de procesos y, finalmente, la innovación de procesos podría mejorar el desempeño organizacional. Este tipo de estructura puede ser útil cuando el fenómeno requiere una explicación progresiva. Sin embargo, cuanto más larga es la cadena conceptual, mayor debe ser la claridad teórica. Un modelo secuencial mal justificado puede convertirse en una ruta artificial difícil de defender. Por ello, los efectos secuenciales deben usarse solo cuando el problema exige explicar una transformación gradual. También deben ser compatibles con la disponibilidad de datos y con el diseño del estudio. En investigación administrativa, las cadenas secuenciales son atractivas porque muchos procesos organizacionales ocurren por etapas; no obstante, los modelos deben mantenerse parsimoniosos. La calidad del sistema conceptual no depende de tener muchas rutas, sino de que cada ruta aporte comprensión. Las buenas prácticas actuales recomiendan evitar modelos innecesariamente complejos y justificar con precisión cada relación agregada al sistema (Guenther et al., 2023).

Un aspecto central de las relaciones conceptuales es la direccionalidad. En un modelo SEM, la dirección de una flecha comunica una suposición conceptual: se espera que una variable anteceda, influya, explique o prediga a otra. Esta dirección no debe decidirse por conveniencia estadística. Debe estar apoyada en la lógica del problema, en la teoría y en el propósito del estudio. Por ejemplo, si se plantea que la confianza influye en la intención de uso, debe justificarse por qué la confianza antecede a la intención y no al revés. Si se afirma que la cultura innovadora favorece el aprendizaje organizacional, debe explicarse por qué esa secuencia tiene sentido. Una mala direccionalidad puede afectar toda la interpretación del modelo. En estudios transversales, además, debe evitarse afirmar causalidad fuerte sin suficiente respaldo temporal. La dirección puede ser teóricamente defendida, pero debe reportarse con prudencia. Por ello, las relaciones conceptuales deben formularse con términos adecuados: relación estructural, influencia esperada, efecto teóricamente propuesto o asociación explicativa. La direccionalidad es necesaria para modelar, pero debe tratarse con rigor y responsabilidad metodológica (Gefen et al., 2000).

La selección de relaciones conceptuales debe cuidar la no redundancia entre variables. Si dos antecedentes representan casi el mismo contenido, el modelo puede volverse conceptualmente repetitivo. Por ejemplo, incluir simultáneamente “madurez digital”, “capacidad digital” y “transformación digital” sin diferenciarlas puede producir solapamiento conceptual. Lo mismo puede ocurrir con “satisfacción”, “confianza” y

"lealtad" si no se definen adecuadamente. La redundancia puede afectar la claridad del sistema conceptual y, más adelante, generar problemas de colinealidad o validez discriminante. Por ello, antes de estimar el modelo, el investigador debe revisar si cada relación conecta constructos realmente distintos. La no redundancia no significa eliminar variables relacionadas, sino asegurar que cada una tenga una función conceptual diferenciada. En SEM, esta revisión es especialmente importante porque los modelos suelen incluir múltiples constructos y relaciones. Un modelo con variables altamente similares puede parecer más completo, pero en realidad puede ser menos interpretable. La construcción de relaciones conceptuales debe buscar **diferenciación, pertinencia y función estructural** (Hair et al., 2021).

Las relaciones conceptuales deben estar alineadas con la pregunta estructural. Si la pregunta central busca explicar cómo las capacidades digitales influyen en el desempeño innovador, el modelo debe organizar sus relaciones alrededor de esa ruta principal. Si se agregan relaciones laterales que no responden a la pregunta, el sistema pierde claridad. La pregunta estructural funciona como filtro: permite decidir qué relaciones se incluyen y cuáles deben quedar fuera. Esto es especialmente importante para mantener la parsimonia. Un modelo puede tener muchas relaciones posibles, pero no todas son necesarias para responder la pregunta de investigación. Por ejemplo, si el objetivo no es estudiar satisfacción del cliente, incluir satisfacción como variable adicional podría desviar el foco del modelo. En una lógica predictiva, también se debe cuidar que los antecedentes seleccionados contribuyan al resultado central y no generen ruido conceptual. La relación entre pregunta y modelo debe ser directa: cada flecha debe ayudar a responder la pregunta. Si una flecha no aporta a esa respuesta, debe justificarse mejor o eliminarse. Así, la pregunta estructural protege la coherencia del sistema conceptual (Shmueli, 2010).

La construcción de relaciones conceptuales también exige distinguir entre variables de control y variables explicativas. Una variable de control se incluye para reducir la influencia de factores externos que podrían afectar la variable resultado, pero no constituye necesariamente el foco teórico del modelo. Por ejemplo, tamaño de empresa, antigüedad, sector o experiencia del usuario pueden actuar como controles si se considera que influyen en el resultado, aunque no sean el interés principal. En cambio, una variable explicativa forma parte central de la lógica del modelo. Confundir ambas puede producir **modelos sobrecargados**. Las variables de control deben incorporarse con prudencia y justificación. No deben añadirse automáticamente ni utilizarse para aparentar rigor. Además, deben ser coherentes con la unidad de análisis y el contexto. En etapas iniciales, basta con que el investigador comprenda que no todas las variables incluidas tienen el mismo papel. **Algunas explican, otras median, otras moderan y otras controlan**. Esta distinción permite construir modelos más claros y preparar una especificación posterior más ordenada. El sistema conceptual gana calidad cuando cada variable tiene una función explícita (Guenther et al., 2023).

Otro punto fundamental es que las relaciones conceptuales deben ser medibles. No basta con que una relación parezca lógica; debe ser posible observar sus constructos mediante indicadores, escalas o datos. Por ejemplo, si se propone que

la cultura innovadora influye en el aprendizaje organizacional, ambos constructos deben poder definirse y medirse. Si se propone una moderación basada en turbulencia ambiental, también debe existir una forma de capturar dicha turbulencia. Esta exigencia no significa agotar todavía la medición, pero sí anticipar su posibilidad. Un sistema conceptual con relaciones imposibles de medir no podrá convertirse en modelo SEM. Además, la posibilidad de medición debe respetar el contexto y la unidad de análisis. Una relación entre constructos organizacionales requiere datos organizacionales o informantes adecuados. Una relación individual requiere indicadores individuales. La medición es el puente entre la relación conceptual y el análisis empírico. En este tema, solo se introduce esta conexión; los capítulos posteriores profundizarán en constructos, indicadores y modelos de medición. La idea central es que toda relación conceptual debe tener una ruta plausible hacia datos observables (Gefen et al., 2000).

La lógica de antecedentes, consecuencias y mecanismos permite ordenar el modelo con jerarquía conceptual. No todas las variables ocupan el mismo lugar ni cumplen la misma función. Los antecedentes se ubican como posibles causas, impulsores o predictores; las consecuencias representan resultados; los mecanismos explican procesos; las condiciones modifican relaciones; y los controles ayudan a aislar efectos. Esta jerarquía evita que el modelo se presente como una red plana donde todo se conecta con todo. En un sistema conceptual sólido, cada constructo tiene posición y función. Por ejemplo, capacidades digitales pueden ser antecedente, aprendizaje organizacional puede ser mecanismo y desempeño innovador puede ser consecuencia. Si además la turbulencia ambiental modifica la relación, actúa como condición. Esta organización facilita la redacción de hipótesis, la construcción del diagrama y la interpretación futura. También permite explicar el modelo a lectores principiantes. La jerarquía conceptual es una herramienta pedagógica: ayuda a entender que el modelo no es solo un conjunto de variables, sino una estructura de razonamiento. En SEM, esta claridad es fundamental para evitar modelos saturados y mejorar la calidad del reporte (Hair et al., 2021).

La relación entre explicación y predicción también debe observarse en la forma de construir antecedentes, consecuencias y mecanismos. En un modelo explicativo, el énfasis está en la justificación conceptual de cada relación; en un modelo predictivo, el énfasis está en la capacidad del conjunto de antecedentes para anticipar una consecuencia. Sin embargo, ambos enfoques necesitan relaciones bien definidas. La predicción no autoriza incluir variables sin sentido conceptual, y la explicación no garantiza utilidad práctica si el modelo no anticipa adecuadamente el resultado. Por ello, el investigador debe construir relaciones que sean coherentes con el propósito declarado. Si el estudio afirma explicar, debe cuidar la lógica de mecanismos. Si afirma predecir, debe cuidar la pertinencia de antecedentes y la variable resultado. Si combina ambos, debe indicar qué relaciones tienen función explicativa y cuáles contribuyen a la predicción. Esta claridad evita conclusiones ambiguas. Un modelo puede ser estadísticamente aceptable y, aun así, conceptualmente confuso si no se sabe qué función cumple cada relación. La lógica relacional debe estar presente desde el sistema conceptual (Shmueli, 2010).

Finalmente, las relaciones conceptuales deben cerrar con una arquitectura preliminar clara. Esta arquitectura debe responder al vacío identificado, a la pregunta estructural y al propósito investigativo. Una formulación útil puede ser: el modelo propone que ciertos antecedentes influyen en una consecuencia principal, posiblemente mediante mecanismos y bajo condiciones específicas. Esta frase permite explicar el modelo antes de dibujarlo. Después, el investigador podrá representar visualmente la relación entre constructos y preparar las hipótesis. Sin embargo, el diagrama solo será válido si refleja una lógica conceptual previa. **Un modelo SEM no se construye con flechas, sino con relaciones conceptuales justificadas** (Guenther et al., 2023).

Construcción del sistema conceptual preliminar antes del modelo SEM

La **construcción del sistema conceptual preliminar** representa el cierre lógico del capítulo 2, porque integra el problema de investigación, los vacíos identificados, la lógica explicativa o predictiva y las relaciones conceptuales en una primera arquitectura modelable. En esta etapa, el investigador todavía no está ejecutando un modelo SEM ni estimando parámetros; está organizando el razonamiento que permitirá justificar posteriormente el modelo. El sistema conceptual preliminar funciona como un **mapa de relaciones** que permite visualizar qué variable será explicada o predicha, qué antecedentes se proponen, qué mecanismos podrían intervenir y qué condiciones podrían modificar las relaciones. Su utilidad principal consiste en evitar que el modelo nazca como una suma de variables aisladas. En lugar de iniciar con el software, el investigador debe iniciar con una estructura conceptual defendible. Esta estructura debe responder con claridad al problema, la pregunta y el propósito del estudio. Si el sistema preliminar no puede explicarse verbalmente antes de graficarse, probablemente aún no está suficientemente maduro para pasar a un modelo SEM (Gefen et al., 2000). As´, se debe considerar

Construir el sistema conceptual preliminar consiste en identificar la variable central. Esta variable representa el resultado principal que se desea explicar o predecir. Puede tratarse de innovación, desempeño organizacional, satisfacción, lealtad, intención de adopción, productividad, competitividad, sostenibilidad o resiliencia. La variable central da dirección al sistema porque permite ordenar todos los demás constructos. Sin ella, el modelo puede convertirse en una red dispersa donde múltiples variables se relacionan sin jerarquía. Por ejemplo, si el problema se centra en la dificultad de las pymes para lograr desempeño innovador, entonces el desempeño innovador debe ocupar el lugar principal del sistema. Los antecedentes, mediadores y moderadores deberán justificarse en función de esa variable. Esta decisión permite mantener **parsimonia**, evitar relaciones innecesarias y preparar la formulación de hipótesis. En SEM, la variable central será después relevante para evaluar la explicación de varianza y la capacidad predictiva, pero en esta etapa su función es conceptual: organizar el sentido del modelo antes de cualquier estimación (Hair et al., 2021).

Seleccionar los antecedentes conceptuales de la variable central. Los antecedentes son factores que podrían influir en el resultado o ayudar a anticiparlo. Su selección debe responder al vacío de investigación y no a la simple disponibilidad de escalas. Por ejemplo, si el vacío consiste en explicar por qué ciertas empresas innovan más que otras, podrían considerarse capacidades digitales, aprendizaje organizacional, orientación al mercado o cultura innovadora. Sin embargo, no todos los antecedentes posibles deben incorporarse. Cada uno debe cumplir una función clara: aportar explicación, mejorar predicción o representar una condición relevante del fenómeno. En una lógica explicativa, los antecedentes deben permitir comprender por qué ocurre la variable resultado; en una lógica predictiva, deben aportar capacidad anticipatoria. Esta distinción evita modelos saturados. Un sistema conceptual preliminar sólido no se construye agregando todas las variables encontradas en la literatura, sino seleccionando aquellas que responden directamente al problema. La calidad del modelo dependerá de la pertinencia de sus relaciones, no de la cantidad de constructos incluidos (Shmueli, 2010).

Definir si el sistema requiere mecanismos mediadores. Un mediador explica cómo o por qué un antecedente se relaciona con una consecuencia. Por ejemplo, las capacidades digitales pueden relacionarse con el desempeño innovador, pero ese efecto podría explicarse mediante el aprendizaje organizacional. En ese caso, el aprendizaje funciona como mecanismo intermedio. La inclusión de mediadores permite pasar de un modelo simple de relación directa a una estructura explicativa más rica. Sin embargo, la mediación no debe incorporarse solo para aumentar complejidad. Debe responder a una necesidad conceptual derivada del problema. Si el vacío de investigación consiste en desconocer el proceso mediante el cual un recurso se transforma en resultado, la mediación puede ser pertinente. Si el vacío solo busca evaluar una relación directa, quizá no sea necesaria. El sistema conceptual preliminar debe distinguir con claridad qué relaciones serán directas y cuáles requieren mecanismos. Esta decisión prepara la formulación posterior de hipótesis y evita que el modelo se vuelva innecesariamente complejo. La mediación debe aportar comprensión, no ornamentación metodológica (Guenther et al., 2023).

Determinar si existen condiciones moderadoras. Una moderación indica que la relación entre dos variables cambia según una condición específica. Mientras la mediación responde al cómo ocurre una relación, la moderación responde al cuándo, para quién o bajo qué circunstancias dicha relación se fortalece, debilita o modifica. En administración, esta lógica resulta relevante porque los fenómenos organizacionales dependen del contexto. Por ejemplo, la relación entre capacidades digitales y desempeño innovador puede ser más fuerte en entornos de alta turbulencia ambiental. La relación entre liderazgo y aprendizaje puede variar según cultura organizacional o tamaño de empresa. No obstante, una moderación solo debe incluirse cuando el problema lo exige. Agregar moderadores sin justificación puede producir modelos difíciles de defender. Además, las moderaciones requieren claridad conceptual, coherencia con la unidad de análisis y viabilidad empírica. En esta etapa, el investigador no necesita agotar la evaluación técnica de interacciones; basta con definir si alguna condición contextual es indispensable para comprender mejor la

relación central. La moderación debe mejorar la lógica del modelo, no solo hacerlo parecer más avanzado (Gefen et al., 2000).

Revisar la unidad de análisis del sistema conceptual preliminar. Toda relación propuesta debe corresponder al nivel de realidad que se estudiará. No es lo mismo construir un modelo sobre individuos que sobre equipos, empresas, instituciones o regiones. Si el modelo analiza intención de uso, probablemente la unidad de análisis sea individual. Si analiza capacidades organizacionales o desempeño empresarial, la unidad de análisis puede ser la empresa. Esta decisión afecta la recolección de datos, la selección de informantes y la interpretación de resultados. Un error frecuente consiste en formular relaciones organizacionales, pero medir únicamente percepciones individuales sin justificar cómo esas respuestas representan a la organización. Otro error es mezclar variables de niveles distintos sin una lógica clara. El sistema conceptual preliminar debe prevenir estas inconsistencias. Antes de dibujar el modelo, el investigador debe responder: **¿quién o qué será observado?, ¿qué representa cada dato?, ¿a qué nivel se interpretarán las conclusiones?**. La unidad de análisis no es un detalle operativo; es una condición básica de coherencia estructural (Hair et al., 2021).

Delimitar el contexto del sistema conceptual. El contexto no debe ser tratado como simple escenario descriptivo, sino como una condición que puede afectar la pertinencia de las relaciones propuestas. Una relación entre transformación digital e innovación puede comportarse de forma distinta en pymes, grandes corporaciones, organizaciones públicas, startups o empresas familiares. Por ello, el sistema conceptual debe indicar dónde ocurre el fenómeno y por qué ese entorno es relevante. Esta delimitación ayuda a evitar generalizaciones excesivas y permite justificar el aporte empírico del estudio. Por ejemplo, analizar capacidades digitales en pymes de servicios puede ser pertinente si se argumenta que estas organizaciones enfrentan restricciones de recursos, presión competitiva o necesidades de adaptación distintas a las de grandes empresas. El contexto también ayuda a decidir si ciertas variables deben actuar como antecedentes, mediadores, moderadores o controles. En modelos con orientación predictiva, el contexto delimita el alcance de la capacidad anticipatoria. En modelos explicativos, ayuda a precisar las condiciones bajo las cuales una relación tiene sentido (Shmueli, 2010).

Asegurar la coherencia entre problema, pregunta, objetivo y sistema conceptual. Un modelo preliminar debe poder rastrearse hacia atrás: cada constructo debe responder a la pregunta; cada relación debe derivarse del problema; cada hipótesis futura debe contribuir al objetivo. Cuando esta coherencia no existe, el sistema conceptual se fragmenta. Por ejemplo, si el problema se centra en desempeño innovador, pero el modelo incluye satisfacción del cliente, liderazgo, confianza y competitividad sin articulación clara, el sistema pierde foco. La coherencia se logra mediante una revisión sencilla: **si elimino esta variable, ¿el modelo pierde capacidad para responder la pregunta?** Si la respuesta es no, quizá la variable no es necesaria. Esta revisión fortalece la parsimonia y evita relaciones accesorias. El sistema conceptual preliminar debe ser suficiente para responder el problema, no

excesivo para aparentar sofisticación. La claridad del modelo se mide por la función de cada elemento. Un constructo sin función debe eliminarse o redefinirse. Una relación sin justificación debe retirarse o replantearse (Guenther et al., 2023).

Construir una matriz conceptual preliminar antes de dibujar el diagrama. Esta matriz puede contener cinco columnas básicas: constructo, función en el modelo, definición conceptual, relación esperada y justificación. Su utilidad es obligar al investigador a explicar cada elemento antes de representarlo visualmente. Por ejemplo, “capacidades digitales” puede aparecer como antecedente; “aprendizaje organizacional” como mediador; “desempeño innovador” como consecuencia. Cada constructo debe tener una definición breve y una razón para estar en el modelo. Esta matriz evita que el diagrama se convierta en una imagen atractiva pero débil. Además, permite detectar redundancias entre constructos, falta de claridad en las relaciones o exceso de complejidad. En SEM, el diagrama suele ser el elemento más visible, pero no debe ser el primero. Antes del diagrama debe existir una matriz lógica. Esta práctica también ayuda al investigador a defender su modelo oralmente y por escrito. Si no puede completar la matriz, el sistema conceptual todavía necesita revisión (Gefen et al., 2000).

Elaborar el diagrama conceptual preliminar. Este diagrama debe representar visualmente la arquitectura del sistema, pero sin convertirse todavía en un modelo técnico de software. Su función es mostrar la variable central, los antecedentes, los mecanismos mediadores, las condiciones moderadoras y la dirección esperada de las relaciones. Un buen diagrama conceptual debe ser claro, legible y parsimonioso. Si tiene demasiadas flechas, puede indicar que el modelo está sobrecargado. Si contiene constructos aislados, quizá existen variables sin función. Si presenta relaciones circulares o contradictorias, debe revisarse la lógica del sistema. El diagrama preliminar no debe diseñarse para impresionar, sino para comunicar. En etapas iniciales, conviene evitar diagramas excesivamente complejos. La complejidad debe introducirse solo cuando el problema la justifica. Más adelante, el modelo podrá traducirse a software; por ahora, el objetivo es verificar que la estructura tenga sentido conceptual. El diagrama es una herramienta de pensamiento, no un sustituto de la argumentación. Cada flecha debe poder explicarse mediante el problema, el vacío y la pregunta estructural (Hair et al., 2021).

Verificar la parsimonia del sistema conceptual. La parsimonia implica incluir solo los elementos necesarios para responder la pregunta de investigación. No significa construir modelos simples por falta de ambición, sino modelos claros por rigor conceptual. Un sistema conceptual con demasiados constructos puede generar problemas de interpretación, medición y viabilidad. Por ejemplo, si se incorporan múltiples antecedentes similares, varios mediadores y distintos moderadores, el modelo puede volverse confuso para el lector y difícil de estimar con una muestra razonable. La parsimonia se evalúa preguntando: **¿cada variable cumple una función distinta?, ¿cada relación responde al problema?, ¿el modelo puede explicarse con claridad?, ¿hay redundancias conceptuales?**. En una lógica predictiva, la parsimonia no elimina la búsqueda de capacidad anticipatoria, pero

impide acumular variables sin sentido. En una lógica explicativa, ayuda a concentrar la teoría en relaciones relevantes. La parsimonia permite que el sistema conceptual sea más elegante, defendible y pedagógicamente útil. Un modelo claro no es aquel que contiene todo, sino aquel que contiene lo necesario (Shmueli, 2010).

Revisar la viabilidad empírica. El sistema conceptual preliminar debe poder convertirse en un estudio realizable. Esto implica preguntarse si los constructos pueden medirse, si existen indicadores posibles, si la población es accesible, si la muestra probable será suficiente y si el número de relaciones es proporcional a los recursos disponibles. Un sistema puede ser conceptualmente interesante, pero inviable si requiere datos longitudinales imposibles, múltiples informantes no disponibles o una muestra excesiva. Esta revisión debe realizarse antes de comprometerse con el modelo. Ajustar el sistema no significa reducir su valor; puede aumentar su rigor. Por ejemplo, un modelo con cinco constructos bien definidos puede ser más sólido que uno con doce variables difíciles de medir. La viabilidad también protege contra el uso mecánico de SEM para justificar modelos demasiado complejos. La técnica puede ser flexible, pero no debe utilizarse para compensar un diseño conceptual inmaduro. El sistema conceptual preliminar debe equilibrar **relevancia, claridad y posibilidad empírica**. La pregunta no es solo qué se quiere estudiar, sino qué se puede estudiar bien (Guenther et al., 2023).

Formular proposiciones o hipótesis preliminares. En esta etapa, las hipótesis no necesitan todavía el desarrollo completo que tendrán en capítulos posteriores, pero sí deben emerger de la lógica del sistema. Si el diagrama propone una relación directa, debe poder expresarse como una hipótesis directa. Si incluye un mediador, debe anticipar una hipótesis de efecto indirecto. Si incluye un moderador, debe señalar cómo cambia la relación principal. Esta formulación preliminar permite comprobar si el sistema conceptual es realmente modelable. Una relación que no puede expresarse como hipótesis probablemente está mal definida. Las hipótesis preliminares deben ser coherentes con el propósito: explicativo, predictivo o mixto. También deben evitar lenguaje causal excesivo cuando el diseño no lo permite. En esta etapa, lo importante es que el investigador pueda traducir el sistema en afirmaciones evaluables. Las hipótesis no deben surgir después del análisis; deben construirse antes, como consecuencia del problema y la pregunta. Esta práctica fortalece la transparencia del estudio y evita que el modelo se ajuste de manera oportunista a los resultados (Gefen et al., 2000).

Anticipar, sin agotar, la relación entre constructos e indicadores. El capítulo 2 no debe desarrollar todavía la evaluación técnica del modelo de medición, pero sí debe recordar que todo constructo incluido tendrá que representarse empíricamente. Por ello, el sistema conceptual preliminar debe preguntarse si cada constructo puede ser medido mediante ítems, escalas, dimensiones, indicadores objetivos o datos secundarios. También debe anticipar si el constructo se comportará como reflectivo, formativo o compuesto, aunque el análisis detallado se reserve para capítulos posteriores. Esta anticipación evita construir modelos con conceptos imposibles de observar. Por ejemplo, si se propone estudiar “madurez estratégica digital”, el

investigador debe prever qué dimensiones o indicadores podrían representarla. Si no existe ninguna ruta clara de medición, el constructo debe redefinirse. La medición no se agota aquí, pero su posibilidad debe estar presente. En SEM, un sistema conceptual solo es útil si puede conectarse con datos. La teoría necesita traducirse en evidencia observable para convertirse en modelo evaluable (Hair et al., 2021).

Definir el alcance del sistema conceptual. El investigador debe decidir si su modelo será exploratorio, explicativo, predictivo, confirmatorio o una combinación justificada. Esta decisión evita que el sistema prometa más de lo que puede ofrecer. Un modelo exploratorio puede servir para organizar relaciones iniciales; uno explicativo requiere fundamentar vínculos teóricos; uno predictivo debe orientarse a anticipar resultados; uno confirmatorio exige mayor solidez teórica previa. En administración, muchos estudios mezclan estos propósitos sin declararlo, lo que genera ambigüedad. El sistema conceptual preliminar debe dejar claro qué tipo de contribución se espera. Si se busca explicar, debe destacarse la lógica de relaciones. Si se busca predecir, debe justificarse la variable resultado y los antecedentes seleccionados. Si se combinan ambos propósitos, se debe indicar cómo se complementan. Esta decisión también ayudará más adelante a seleccionar la técnica SEM adecuada. Por ahora, el objetivo es que el modelo no nazca ambiguo. El alcance actúa como límite metodológico y como guía de interpretación futura (Shmueli, 2010).

Preparar la defensa metodológica inicial del sistema conceptual. Antes de estimar cualquier modelo, el investigador debe poder justificar por qué eligió esos constructos y no otros, por qué colocó cada variable en determinada posición, por qué propuso cada relación y por qué el sistema responde al vacío identificado. Esta defensa no depende de resultados estadísticos; depende de la coherencia del razonamiento. Un modelo no se vuelve sólido porque los coeficientes resulten significativos; debe ser sólido antes de estimarse. Esta idea es fundamental para evitar el uso superficial de SEM. La defensa metodológica inicial debe incluir cinco argumentos: pertinencia del problema, claridad de la variable central, justificación de antecedentes, necesidad de mediadores o moderadores y viabilidad de medición. Si alguno de estos elementos es débil, el sistema debe revisarse. En buenas prácticas de investigación con PLS-SEM, la justificación del modelo es tan importante como el reporte de resultados. Por ello, el sistema conceptual preliminar debe cerrarse con una narrativa que explique el modelo de manera clara y convincente (Guenther et al., 2023).

En conclusión, la construcción del sistema conceptual preliminar permite pasar del problema de investigación a una arquitectura modelable sin adelantar todavía la evaluación técnica completa. Este sistema debe integrar variable central, antecedentes, mecanismos, condiciones, contexto, unidad de análisis, hipótesis preliminares y viabilidad empírica. Su función es asegurar que el modelo SEM no sea una figura improvisada ni una operación de software, sino una consecuencia lógica del razonamiento metodológico. En este punto, el investigador debe aprender a construir un modelo que pueda defenderse antes de ser estimado. La pregunta si el sistema conceptual tiene sentido. Un buen sistema preliminar debe ser **claro, parsimonioso,**

coherente, medible y alineado con el propósito investigativo. Con este cierre, preparamos el avance hacia el siguiente capítulo, donde la teoría comenzará a organizarse en variables e hipótesis con mayor precisión estructural (Gefen et al., 2000).

Conclusiones

El Capítulo 2 permite concluir que **el problema de investigación no debe entenderse como una simple descripción temática**, sino como la **tensión científica que da origen al modelo**. Un problema bien formulado identifica qué falta explicar, predecir, medir o contextualizar, y permite traducir esa ausencia en una primera arquitectura de variables, constructos y relaciones. Por ello, antes de avanzar hacia técnicas SEM, el investigador debe demostrar que el problema puede convertirse en un sistema conceptual coherente, medible y defendible (Gefen et al., 2000).

Una segunda conclusión es que **el sistema conceptual funciona como puente entre el problema y el modelo estructural**. No es todavía el diagrama definitivo ni el análisis estadístico, sino una representación razonada de cómo se entiende el fenómeno. En esta etapa se define la variable central, se seleccionan antecedentes pertinentes, se anticipan mecanismos mediadores, se reconocen posibles condiciones moderadoras y se delimita la lógica general de relación entre constructos (Hair et al., 2021).

El capítulo también muestra que **todo modelo debe partir de un vacío de investigación claramente identificado**. Los vacíos teórico, empírico, metodológico y práctico no son etiquetas decorativas, sino razones académicas que justifican la investigación. El vacío teórico fortalece la explicación conceptual; el empírico justifica estudiar un contexto específico; el metodológico señala limitaciones en la forma de medir o analizar; y el práctico conecta el modelo con necesidades reales de organizaciones, instituciones o mercados (Guenther et al., 2023).

Otra conclusión relevante es que **explicar y predecir no son equivalentes**. La explicación busca comprender por qué ocurre un fenómeno y mediante qué mecanismos se produce; la predicción busca anticipar un resultado con base en sus antecedentes. En ciencias de la administración, ambos propósitos pueden combinarse, pero deben declararse con claridad desde el diseño, porque afectan la pregunta de investigación, la selección de variables, la formulación de hipótesis y la interpretación posterior del modelo (Shmueli, 2010).

Finalmente, el capítulo permite afirmar que **la calidad de un modelo SEM depende de la claridad conceptual previa, no solo de los indicadores estadísticos posteriores**. Un modelo no es más sólido por incluir más variables, más flechas o más relaciones, sino por integrar únicamente los elementos necesarios para responder el problema. La parsimonia, la viabilidad, la unidad de análisis, el contexto y la coherencia entre problema, vacío, pregunta, variables e hipótesis son condiciones indispensables para avanzar hacia un modelo estructural riguroso. En este sentido, el Capítulo 2

prepara la construcción del sistema conceptual preliminar antes del modelo SEM y evita que el investigador confunda el uso del software con la fundamentación científica del modelo (Hair et al., 2021). Véase la **Tabla 2**.

Tabla 2. Sistema conceptual y lógica del modelo

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Antecedente	Variable o constructo ubicado antes de una consecuencia dentro de una relación conceptual.	Permite construir rutas explicativas o predictivas hacia la variable central del modelo.	Debe justificarse por su capacidad conceptual para influir en el resultado estudiado.	Chin (1998); Hair et al. (2021).
Arquitectura conceptual	Estructura lógica que organiza problema, vacío, variables, constructos y relaciones.	Permite visualizar el modelo antes de formular hipótesis o estimarlo estadísticamente.	Evita modelos improvisados, acumulativos o construidos solo desde el software.	Chin (1998); Henseler (2017).
Coherencia metodológica	Correspondencia entre problema, pregunta, objetivos, variables, hipótesis, unidad de análisis y método.	Garantiza que el sistema conceptual tenga lógica interna antes de avanzar al análisis SEM.	La incoherencia entre elementos debilita el modelo aunque después existan resultados estadísticos aceptables.	Gefen et al. (2000); Hair et al. (2021).
Consecuencia	Resultado que el modelo busca explicar o predecir.	Ordena antecedentes, mecanismos y dirección conceptual del sistema.	Evita modelos sin jerarquía, sin variable de llegada o sin propósito estructural claro.	Shmueli (2010); Hair et al. (2021).
Constructo	Concepto abstracto que requiere definición conceptual y posterior medición mediante indicadores.	Constituye la unidad conceptual básica del sistema SEM.	Debe definirse antes de operacionalizarse o medirse.	Churchill (1979); Jarvis et al. (2003).
Contexto	Escenario empírico, organizacional, sectorial, institucional o territorial donde ocurre el fenómeno.	Delimita el alcance del modelo y orienta la interpretación de las relaciones.	Puede justificar vacíos empíricos cuando el escenario modifica la comprensión del fenómeno.	Henseler (2017); Guenther et al. (2023).
Contribución esperada	Aporte teórico, empírico, metodológico o práctico derivado del vacío identificado.	Vincula el vacío de investigación con el valor académico y aplicado del estudio.	Debe corresponder directamente al vacío principal, no formularse como promesa general.	Guenther et al. (2023); Henseler (2017).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Delimitación	Definición precisa de lo que el estudio incluye y excluye.	Evita modelos demasiado amplios, ambiguos o inviables.	Fortalece la precisión conceptual, contextual y metodológica del modelo.	Hair et al. (2021); Henseler (2017).
Direccionalidad	Sentido esperado de la relación entre variables o constructos.	Permite formular hipótesis y construir el modelo gráfico preliminar.	Debe derivarse de teoría, lógica temporal y coherencia conceptual.	Chin (1998); Gefen et al. (2000).
Efecto secuencial	Relación indirecta que ocurre mediante varios pasos o constructos intermedios.	Representa cadenas explicativas dentro del sistema conceptual.	Requiere fuerte justificación teórica y temporal para evitar complejidad decorativa.	Hair et al. (2021); Shmueli (2010).
Explicación	Comprensión de por qué ocurre un fenómeno o relación.	Guía la selección conceptual de variables, mecanismos y relaciones.	Es adecuada cuando el estudio busca comprender procesos, causas o rutas conceptuales.	Shmueli (2010); Henseler (2017).
Falso vacío	Justificación débil que aparenta una brecha, pero no demuestra relevancia científica.	Debilita la contribución y la pertinencia del modelo.	No basta afirmar que “hay pocos estudios”; debe explicarse por qué esa ausencia importa.	Guenther et al. (2023); Henseler (2017).
Fenómeno investigable	Parte de la realidad que se observa, delimita y convierte en objeto de análisis.	Define el campo de observación del estudio antes de formular el problema.	Debe diferenciarse del problema de investigación, porque observar un fenómeno no equivale aún a explicar una tensión científica.	Henseler (2017); Hair et al. (2021).
Hipótesis preliminar	Relación esperada entre constructos antes de su contrastación empírica.	Prepara la transición del sistema conceptual al modelo estructural.	Debe surgir del problema, del vacío y de la lógica conceptual, no del deseo de obtener significancia estadística.	Chin (1998); Gefen et al. (2000).
Indicador	Manifestación observable que permitirá medir un constructo en una etapa posterior.	Anticipa la futura operacionalización de los conceptos.	En el Capítulo 2 solo se reconoce su necesidad; su evaluación técnica corresponde a capítulos posteriores.	Churchill (1979); Hair et al. (2021).
Lógica explicativa-predictiva	Integración entre comprensión conceptual y	Orienta el propósito del modelo y la	Debe declararse desde el diseño, no añadirse al final	Shmueli (2010); Hair et al. (2019).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	capacidad de anticipar resultados.	selección de variables.	para justificar resultados.	
Mecanismo	Proceso intermedio que explica cómo una variable antecedente se relaciona con una consecuencia.	Da profundidad explicativa a las relaciones conceptuales.	Debe aportar explicación real, no solo aumentar la complejidad del modelo.	Hair et al. (2021); Shmueli (2010).
Mediación	Variable intermedia que transmite el efecto de una variable sobre otra.	Explica cómo o por qué ocurre una relación.	Debe tener sentido conceptual, lógico y temporal dentro del sistema.	Hair et al. (2021); Gefen et al. (2000).
Moderación	Variable que cambia la fuerza o dirección de una relación.	Explica bajo qué condiciones una relación se fortalece, debilita o modifica.	Debe justificarse por condiciones contextuales relevantes, no agregarse por sofisticación artificial.	Hair et al. (2021); Shmueli (2010).
Modelo decorativo	Modelo visualmente complejo, pero conceptualmente débil.	Representa una debilidad metodológica antes de la estimación.	Debe evitarse porque multiplica flechas sin función conceptual clara.	Guenther et al. (2023); Henseler (2017).
Modelo gráfico preliminar	Representación visual inicial del sistema conceptual.	Ayuda a revisar jerarquía, dirección y función de las relaciones.	Cada flecha debe poder justificarse verbalmente antes de estimarse.	Chin (1998); Hair et al. (2021).
Objetivo de investigación	Propósito formal que expresa qué busca lograr el estudio.	Alinea problema, pregunta, variables, hipótesis y método.	Debe expresar claramente el alcance, el propósito y la relación con el vacío.	Gefen et al. (2000); Hair et al. (2021).
Parsimonia	Inclusión solo de variables y relaciones necesarias.	Reduce saturación conceptual y mejora la claridad del modelo.	Más variables no significan mejor modelo; un modelo claro puede ser más sólido que uno excesivamente complejo.	Hair et al. (2021); Guenther et al. (2023).
Predicción	Anticipación de resultados mediante variables antecedentes.	Evalúa la capacidad del modelo para prever una consecuencia.	No equivale automáticamente a explicación teórica; ambas lógicas deben distinguirse.	Shmueli (2010); Hair et al. (2019).
Pregunta de investigación	Interrogante central derivada del problema.	Orienta sistema conceptual, variables, relaciones e hipótesis.	Debe corresponder al problema y al vacío identificado.	Gefen et al. (2000); Chin (1998).
Pregunta estructural	Pregunta formulada en términos de	Permite pasar del problema al modelo SEM.	Debe poder representarse mediante relaciones	Chin (1998); Hair et al. (2021).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	relaciones entre constructos.		conceptualmente justificables y estadísticamente modelables.	
Problema de investigación	Tensión científica derivada de algo insuficientemente explicado, relacionado, medido, contextualizado o anticipado.	Punto de partida para formular pregunta, objetivos, variables, hipótesis y sistema conceptual.	Debe traducirse en relaciones conceptuales entre constructos, no quedarse como descripción general del fenómeno.	Gefen et al. (2000); Hair et al. (2019).
Redundancia conceptual	Presencia de constructos con contenidos demasiado similares.	Puede afectar claridad, delimitación conceptual e interpretación futura del modelo.	Deben redefinirse, fusionarse o eliminarse para evitar traslapes conceptuales.	Jarvis et al. (2003); Henseler et al. (2015).
Relación conceptual	Conexión razonada entre dos constructos.	Es la base de hipótesis, rutas y modelo estructural posterior.	Toda flecha futura debe justificarse conceptualmente.	Chin (1998); Henseler (2017).
Relación directa	Influencia inmediata de un constructo sobre otro.	Representa una ruta estructural simple.	Debe tener soporte teórico claro y dirección justificable.	Gefen et al. (2000); Hair et al. (2021).
Relación indirecta	Influencia que ocurre mediante uno o más constructos intermedios.	Permite representar mecanismos y procesos explicativos.	Es útil para comprender cómo ocurre una relación, no solo si existe asociación.	Hair et al. (2021); Shmueli (2010).
Sistema conceptual	Organización preliminar de variables, constructos y relaciones.	Funciona como puente entre problema, teoría y modelo SEM.	Debe ser claro, viable, parsimonioso, medible y defendible.	Chin (1998); Hair et al. (2021).
Trazabilidad conceptual	Ruta lógica desde problema, vacío y pregunta hasta variables, hipótesis y relaciones.	Verifica el origen y justificación de cada relación del modelo.	Es fundamental para evaluar la coherencia académica del estudio.	Guenther et al. (2023); Henseler (2017).
Unidad de análisis	Nivel al que se refiere el estudio: individuo, equipo, empresa, institución, región o ecosistema.	Define la interpretación de variables, datos e inferencias.	Debe alinearse con problema, población, muestra e indicadores.	Gefen et al. (2000); Hair et al. (2021).
Uso mecánico de PLS-SEM	Aplicación de la técnica sin justificación conceptual ni metodológica.	Representa una debilidad del diseño de investigación.	La técnica no sustituye el razonamiento conceptual; el modelo debe justificar la técnica.	Guenther et al. (2023); Hair et al. (2019).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Vacío de investigación	Brecha de conocimiento que justifica el estudio.	Orienta pregunta, variables, relaciones y contribución.	Sin vacío, el modelo puede volverse arbitrario o meramente descriptivo.	Henseler (2017); Guenther et al. (2023).
Vacío empírico	Falta de evidencia en contextos, poblaciones, sectores o escenarios específicos.	Justifica estudiar el fenómeno en un contexto determinado.	Es válido si el contexto puede modificar la comprensión, explicación o predicción del fenómeno.	Guenther et al. (2023); Hair et al. (2021).
Vacío metodológico	Limitación en la forma de medir, especificar, estimar o evaluar un fenómeno.	Justifica mejoras en diseño, medición o estrategia analítica.	Debe mejorar la comprensión del fenómeno, no solo añadir complejidad técnica.	Hair et al. (2021); Guenther et al. (2023).
Vacío práctico	Necesidad organizacional, institucional o administrativa no resuelta.	Vincula el modelo con toma de decisiones y utilidad aplicada.	Debe traducirse en variables, relaciones y consecuencias observables.	Henseler (2017); Shmueli (2010).
Vacío teórico	Falta de explicación conceptual sobre una relación, mecanismo o condición.	Justifica relaciones, mediaciones o moderaciones.	Debe señalar con precisión qué explicación falta.	Henseler (2017); Chin (1998).
Variable central	Resultado principal que se desea explicar o predecir.	Organiza la dirección del sistema conceptual.	Sin ella, el modelo pierde jerarquía, dirección y sentido estructural.	Hair et al. (2019); Shmueli (2010).
Variable de control	Variable usada para aislar o ajustar relaciones principales.	Controla efectos externos que podrían afectar la interpretación conceptual.	No debe agregarse automáticamente; requiere justificación teórica o metodológica.	Gefen et al. (2000); Hair et al. (2021).
Variable dependiente	Constructo que recibe influencia de otros constructos.	Es el punto de llegada de las relaciones estructurales.	Debe conectarse directamente con problema, vacío y objetivo.	Gefen et al. (2000); Hair et al. (2021).
Variable explicativa	Constructo antecedente que ayuda a explicar o predecir una consecuencia.	Aporta sentido a la estructura causal o predictiva del modelo.	Debe incluirse por necesidad conceptual, no por moda académica o disponibilidad de escalas.	Gefen et al. (2000); Hair et al. (2019).
Viabilidad	Posibilidad real de ejecutar el modelo con datos, muestra, indicadores y recursos disponibles.	Asegura factibilidad empírica del sistema conceptual.	Un modelo pequeño y coherente puede ser mejor que uno amplio, saturado o inviable.	Cohen (1992); Green (1991).

Fuente: recopilación y elaboración propia

CAPÍTULO 3. De la teoría a las variables

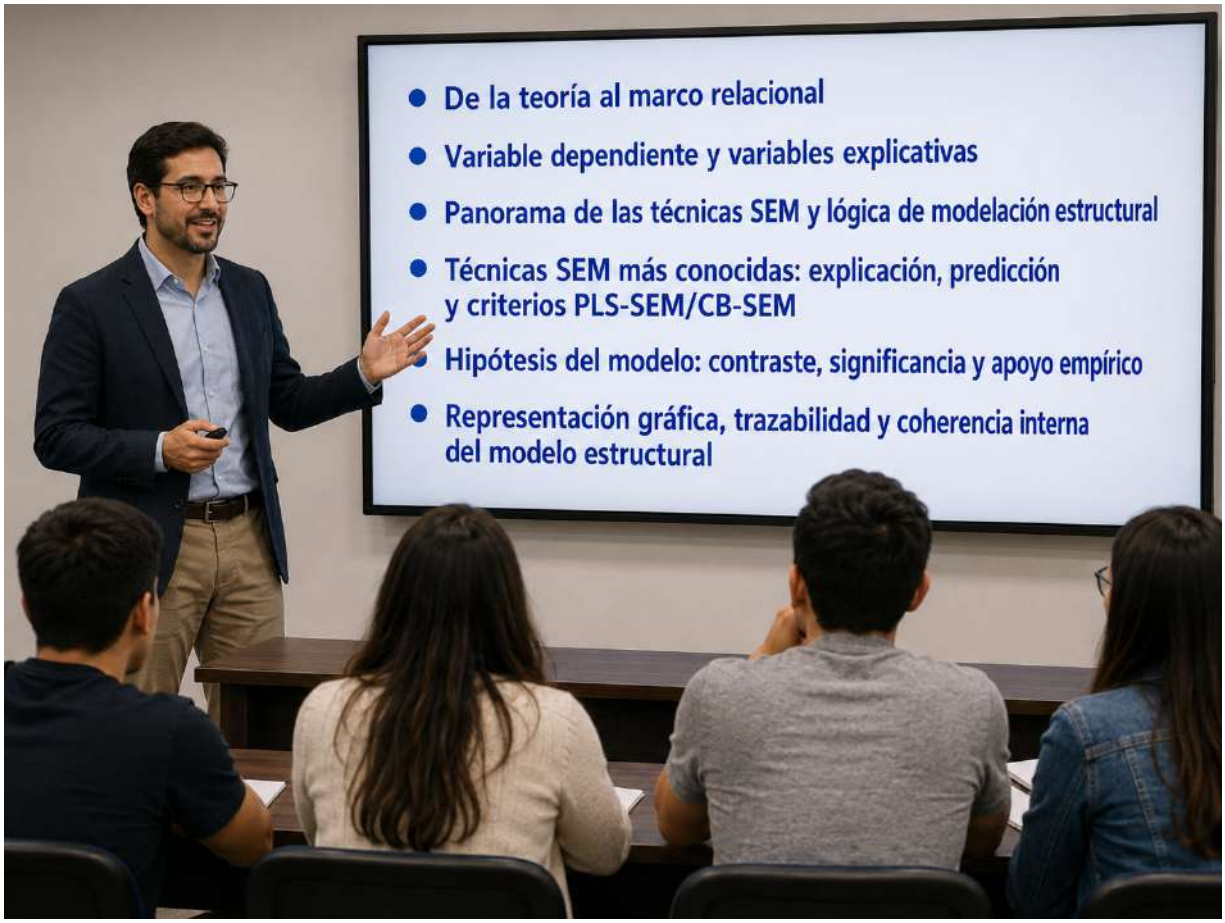

El Capítulo 3, explica el momento en que la investigación deja de ser una formulación conceptual general y comienza a convertirse en una **arquitectura estructural susceptible de análisis SEM**. En los capítulos anteriores, el investigador ha delimitado el fenómeno, ha formulado el problema y ha reconocido los principales vacíos teóricos, empíricos, metodológicos o prácticos. Sin embargo, para avanzar hacia un modelo de ecuaciones estructurales no basta con identificar conceptos relevantes; es necesario establecer **cómo se relacionan entre sí, qué función cumple cada constructo, cuál es la variable central del modelo y cuáles rutas pueden formularse como hipótesis evaluables**. Por ello, este capítulo se concentra en el tránsito desde la teoría hacia un **sistema de relaciones organizado**, donde cada flecha del modelo debe tener fundamento conceptual y no responder únicamente a intuiciones, correlaciones preliminares o posibilidades ofrecidas por el software. En SEM, la teoría no es un antecedente decorativo, sino el fundamento que permite justificar la dirección, pertinencia y función de cada **vínculo estructural** (Chin, 1998)

El capítulo inicia con la identificación de la **variable dependiente** o constructo resultado, porque todo **modelo estructural** requiere un eje que organice las demás relaciones. **Esta variable representa aquello que el investigador desea explicar o predecir, por ejemplo: desempeño innovador, intención de uso, satisfacción, aprendizaje organizacional, sostenibilidad, competitividad, resiliencia o adopción tecnológica**. Una vez definido el resultado central, es posible seleccionar con mayor claridad las variables explicativas, los posibles mediadores, los moderadores y las variables de control pertinentes. Esta organización evita modelos saturados, redundantes o construidos por acumulación de constructos. En consecuencia, **el modelo** no debe entenderse como una red libre de relaciones, sino como un sistema jerárquico donde cada constructo cumple una función dentro de la explicación del fenómeno. Esta lógica es especialmente importante en PLS-SEM y CB-SEM, porque ambos enfoques exigen coherencia entre teoría, medición, hipótesis y criterios de evaluación (Hair et al., 2021).

Posteriormente, el capítulo introduce el **panorama de las técnicas SEM y la lógica de modelación estructural**, con el propósito de mostrar que SEM no es una técnica única ni un software específico, sino una familia metodológica amplia. En esta familia se ubican el análisis de trayectoria, el análisis factorial confirmatorio, los modelos multigrupo, la invariancia de medición, los modelos de mediación, moderación, segundo orden, crecimiento latente, ecuaciones simultáneas, GSCA, PLSc, modelos formativos, modelos compuestos, regresión con **puntiuaciones agregadas (sum scores)** y análisis de componentes principales. Sin embargo, por su difusión en investigación aplicada con constructos latentes, el capítulo desarrolla con mayor detalle **CB-SEM y PLS-SEM**. **CB-SEM** se asocia principalmente con la confirmación teórica, el ajuste global y la lógica basada en covarianzas; **PLS-SEM** se vincula con explicación de varianza, predicción, modelos complejos y constructos reflectivos, formativos o compuestos. Esta distinción permite que el investigador no elija una técnica por moda o facilidad operativa, sino por congruencia con el propósito del estudio (Henseler, 2017; Hair et al., 2019).

Asimismo, el capítulo enfatiza que **la medición y la estructura no pueden separarse completamente**. Aunque la evaluación detallada del modelo de medición corresponde a apartados específicos, en este punto resulta necesario recordar que ninguna relación estructural es interpretable si los constructos no han sido definidos y operacionalizados con rigor. Las variables latentes requieren indicadores válidos, confiables y conceptualmente pertinentes. Por ello, antes de interpretar rutas, coeficientes, efectos directos, efectos indirectos o hipótesis, el investigador debe asegurar que sus constructos cuentan con evidencia suficiente de confiabilidad, validez convergente, validez discriminante y ausencia de colinealidad problemática. Esta precisión es relevante porque un modelo puede tener relaciones estadísticamente significativas y, aun así, ser débil si sus constructos no están claramente diferenciados o si sus indicadores no representan adecuadamente el contenido conceptual previsto (Fornell & Larcker, 1981; Henseler et al., 2015).

Finalmente, el capítulo conduce al lector hacia la formulación de **hipótesis estructurales** y la representación gráfica del modelo. **Una hipótesis no debe redactarse como una expectativa general, sino como una relación precisa entre constructos, con dirección esperada, fundamento teórico y posibilidad de contraste empírico.** En este sentido, el modelo gráfico cumple una función de trazabilidad: muestra cómo el problema de investigación se traduce en constructos, cómo esos constructos se conectan mediante relaciones justificadas y cómo esas relaciones podrán evaluarse posteriormente mediante coeficientes, valores t, valores p, intervalos de confianza, efectos directos, indirectos y totales. Así, el Capítulo 3 establece el puente entre la fundamentación teórica y la evaluación SEM, preparando al investigador para construir modelos conceptualmente defendibles, metodológicamente viables y empíricamente evaluables (Gefen et al., 2000)

De la teoría al marco relacional

La **teoría** es el fundamento que permite transformar un conjunto de conceptos en un **marco relacional** capaz de sostener un modelo SEM. En esta etapa, el investigador ya no se limita a definir términos, sino que debe explicar cómo los conceptos se conectan entre sí para responder el problema de investigación. Por ejemplo, no basta con afirmar que **capacidades digitales**, **aprendizaje organizacional** y **desempeño innovador** son relevantes en administración; es necesario justificar por qué las capacidades digitales podrían favorecer el aprendizaje y por qué dicho aprendizaje podría traducirse en innovación. Esta transición convierte la teoría en una **estructura argumentativa**. Cada relación propuesta debe responder a una pregunta central: **¿por qué este constructo debe vincularse con este otro dentro del modelo?**. En SEM, una flecha no debe representar una intuición ni una ocurrencia gráfica; debe representar una relación conceptualmente sustentada. Por ello, el marco relacional cumple una función metodológica clave: ordenar los constructos, asignarles función, establecer direccionalidad y preparar hipótesis defendibles. Sin esta etapa, el modelo puede parecer visualmente correcto, pero carecer de fundamento conceptual. La calidad del análisis estructural inicia antes del software, cuando la teoría permite construir relaciones con sentido, coherencia y pertinencia metodológica (Gefen et al., 2000).

El **marco relacional** debe iniciar con la identificación de una **variable central**, porque todo modelo necesita un eje que organice las demás relaciones. Esta variable representa el resultado que se desea explicar o predecir: **desempeño innovador**, satisfacción, intención de adopción, lealtad, productividad, competitividad, sostenibilidad o resiliencia. Sin una variable central, el modelo se vuelve una red dispersa donde las variables se conectan sin jerarquía. Si el fenómeno de interés es el desempeño innovador, entonces los antecedentes, mediadores y moderadores deben justificar su relación con ese resultado. La variable central permite decidir qué relaciones son necesarias y cuáles son accesorias. En modelos PLS-SEM, donde existe flexibilidad para trabajar con estructuras complejas, esta claridad es indispensable para evitar modelos sobredimensionados. Un modelo no debe crecer

por acumulación, sino por **necesidad conceptual**. Por ello, el investigador debe preguntarse: **¿qué resultado deseo comprender?, ¿qué variables ayudan a explicarlo?, ¿qué relaciones son indispensables para responder mi pregunta?**. Esta centralidad fortalece la parsimonia y permite construir un marco relacional más claro, defendible y alineado con el propósito del estudio. La variable central no solo organiza el diagrama; organiza la literatura, la argumentación, las hipótesis y la interpretación futura de resultados (Hair et al., 2021).

Un marco relacional sólido exige definir la función específica de cada constructo. Un mismo constructo puede ocupar posiciones distintas según el problema. El **aprendizaje organizacional**, por ejemplo, puede ser variable dependiente si el estudio busca explicar cómo aprenden las organizaciones; puede ser variable explicativa si se analiza su efecto sobre la innovación; o puede ser mediador si se propone que transmite el efecto de las capacidades digitales hacia el desempeño. Esta flexibilidad exige precisión conceptual. Ningún constructo tiene una posición fija en todos los modelos. Su lugar depende de la **pregunta estructural**, del vacío de investigación y del propósito metodológico. Por ello, antes de formular hipótesis, el investigador debe establecer si cada constructo funcionará como **antecedente**, **consecuencia**, **mediador**, **moderador** o **control**. Esta decisión no es solamente técnica; es una decisión teórica. Cuando una variable aparece en el modelo sin función clara, el sistema pierde interpretación. En cambio, cuando cada constructo cumple una tarea específica, el modelo gana coherencia. La teoría permite asignar funciones y evitar que el diagrama se convierta en un conjunto de elementos atractivos, pero conceptualmente desordenados. Un modelo estructural no se justifica por la cantidad de constructos incluidos, sino por la claridad con la que cada constructo contribuye al fenómeno estudiado (Chin, 1998).

La teoría también ayuda a diferenciar entre relaciones nucleares, **relaciones complementarias** y **relaciones accesorias**. Las relaciones nucleares sostienen directamente la pregunta de investigación; las complementarias amplían la comprensión del fenómeno; y las accesorias, aunque pueden ser interesantes, no son indispensables para el modelo. Esta distinción es fundamental para evitar la saturación conceptual. Por ejemplo, si el estudio busca explicar cómo las capacidades digitales se traducen en desempeño innovador mediante aprendizaje organizacional, esa ruta debe ocupar el centro del marco relacional. Incluir liderazgo, cultura, orientación al mercado o recursos financieros solo sería pertinente si esas variables cumplen una función clara dentro del vacío identificado. De lo contrario, el modelo pierde foco. La teoría no solo sirve para agregar variables; también sirve para excluirlas con criterio. La **selección relacional** es una forma de rigor, porque obliga al investigador a justificar por qué una relación entra y por qué otra queda fuera. En SEM, un modelo más grande no necesariamente es mejor. Un modelo es mejor cuando cada vínculo contribuye de manera directa a responder el problema. La fuerza del marco relacional reside en su coherencia, no en la cantidad de flechas. Esta perspectiva evita modelos inflados y fortalece la defensa metodológica del estudio (Hair et al., 2019).

El marco relacional debe cuidar la direccionalidad conceptual. En SEM, cada flecha comunica una expectativa: se supone que una variable antecede, influye o contribuye a explicar otra. Esta dirección no debe elegirse por conveniencia estadística ni por estética del diagrama. Debe derivarse de la teoría, del problema y de la lógica temporal del fenómeno. Si se propone que la **confianza** influye en la **intención de adopción**, debe explicarse por qué la confianza antecede conceptualmente a la intención. Si se plantea que las **capacidades digitales** influyen en el **desempeño innovador**, debe argumentarse que dichas capacidades habilitan procesos que posteriormente generan resultados. Esta dirección no prueba causalidad por sí misma, pero vuelve razonable la hipótesis. En diseños transversales, el investigador debe ser especialmente prudente: puede proponer relaciones estructurales esperadas, pero no afirmar causalidad fuerte sin respaldo suficiente. La teoría permite construir dirección; el diseño define el alcance de la inferencia. Por ello, el marco relacional debe usar un lenguaje cuidadoso: **relación esperada**, **efecto hipotetizado**, **influencia teóricamente propuesta** o **asociación estructural**, según corresponda. La dirección de una relación debe ser defendible antes de que sea estimada, porque el software no puede corregir una flecha conceptualmente mal orientada (Gefen et al., 2000).

Otra función del marco relacional es distinguir entre relaciones necesarias y **relaciones posibles**. La literatura puede sugerir muchas conexiones entre variables, pero no todas deben incorporarse. Una relación posible tiene sentido general; una relación necesaria es indispensable para responder la pregunta central. Por ejemplo, la **cultura organizacional** puede relacionarse con innovación, liderazgo, aprendizaje, compromiso y desempeño. Sin embargo, si el modelo se concentra en capacidades digitales, aprendizaje organizacional y desempeño innovador, la cultura solo debe incluirse si fortalece directamente la ruta explicativa. Esta distinción protege la **parsimonia estructural**. El investigador debe preguntarse: **si elimino esta relación, ¿se debilita la respuesta a mi pregunta de investigación?**. Si la respuesta es no, probablemente la relación no pertenece al modelo principal. Esta práctica evita modelos inflados, reduce redundancias y mejora la claridad del argumento. La construcción del marco relacional exige disciplina: no se trata de demostrar todo lo que la literatura permite conectar, sino de construir la ruta más coherente para responder el problema. La precisión del modelo depende de esa capacidad de selección. En un modelo SEM, la exclusión razonada de relaciones puede ser tan importante como la inclusión de relaciones relevantes (Hair et al., 2021).

El marco relacional debe diferenciar entre justificación teórica y **justificación empírica previa**. La justificación teórica explica por qué una relación debería existir; la justificación empírica muestra que esa relación ha sido observada en estudios anteriores. Ambas son útiles, pero ninguna sustituye a la otra. Citar estudios previos no basta si no se explica por qué sus hallazgos son pertinentes para el nuevo contexto. Del mismo modo, invocar una teoría general no basta si no se traduce al fenómeno específico. En SEM, cada referencia debe cumplir una función dentro del argumento: sostener una relación, justificar una dirección, fundamentar una mediación, explicar una moderación o delimitar un constructo. La literatura no debe utilizarse para llenar espacio, sino para construir **argumentos relacionales**. Un buen marco relacional no

pregunta solamente “qué autores hablan del tema”, sino **qué relación permite sostener cada autor**. Esta forma de leer la literatura mejora la calidad del modelo, porque cada cita contribuye a defender una parte de la arquitectura conceptual. La teoría se vuelve útil cuando ayuda a explicar por qué una flecha debe existir. Así, el marco relacional transforma la revisión de literatura en una secuencia de argumentos vinculados con la pregunta estructural del estudio (Chin, 1998).

La construcción del marco relacional también requiere reconocer la **compatibilidad entre teoría y método**. Una teoría puede sugerir relaciones complejas, pero el diseño metodológico debe permitir evaluarlas de manera razonable. Por ejemplo, un modelo con varias mediaciones en serie, múltiples moderaciones y numerosos constructos puede parecer sofisticado, pero quizá sea inviable con una muestra reducida o con mediciones débiles. De igual forma, si la teoría sugiere causalidad fuerte, pero el estudio será transversal, la redacción debe ser prudente. La teoría orienta el modelo, pero el método define sus posibilidades de evaluación. Esta compatibilidad evita prometer más de lo que el estudio puede sostener. En esta etapa no se trata de calcular índices, sino de construir criterio metodológico. El investigador debe comprender que un modelo no es mejor por ser más complejo, sino por ser **teóricamente pertinente**, **metodológicamente viable** y **empíricamente evaluable**. El marco relacional debe anticipar esos límites sin agotar todavía la evaluación técnica. Esta coherencia será indispensable cuando el modelo avance hacia hipótesis, medición y análisis estructural. Un modelo viable no es el que incluye todo, sino aquel que puede defender sus relaciones y evaluarlas con datos adecuados (Hair et al., 2019).

El marco relacional debe evitar la **circularidad conceptual**. Esta ocurre cuando dos constructos se definen de manera tan cercana que uno parece contener al otro, pero luego se presentan como variables separadas. Por ejemplo, si se define **desempeño innovador** como la capacidad de generar innovaciones exitosas y después se usa **capacidad de innovación** como antecedente sin diferenciarlas, la relación puede volverse tautológica. También puede ocurrir cuando se define **transformación digital** mediante capacidades digitales y luego se colocan ambas al mismo nivel explicativo. La circularidad debilita el modelo porque la relación deja de aportar explicación real. Antes de proponer una relación, el investigador debe verificar que los constructos sean conceptualmente distintos. Esta revisión antecede a cualquier prueba estadística de validez discriminante. El marco relacional debe separar conceptos, establecer jerarquías y evitar que una variable explique algo que ya está contenido en su propia definición. La **diferenciación conceptual** es una condición básica para construir relaciones útiles. Un modelo solo es interpretable cuando sus constructos representan ideas distinguibles. Si dos conceptos son prácticamente equivalentes, la relación entre ellos no explica; solo repite con otro nombre el mismo contenido (Gefen et al., 2000).

Una función avanzada del marco relacional es reconocer rutas alternativas plausibles sin saturar el modelo. En muchos fenómenos administrativos existen varias explicaciones posibles. Las capacidades digitales podrían influir en el desempeño innovador mediante aprendizaje organizacional, agilidad, colaboración,

orientación al mercado o cultura innovadora. Sin embargo, el investigador debe seleccionar la ruta que mejor responda al vacío identificado**. No es necesario incluir todas las rutas posibles.** Lo importante es justificar por qué se elige una y no otra. Esta decisión muestra madurez conceptual, porque reconoce la complejidad del fenómeno sin intentar abarcarla por completo. Un modelo SEM no pretende representar toda la realidad, sino una explicación **acotada, plausible y evaluable**. El marco relacional debe ser selectivo, no totalizante. La calidad del modelo aumenta cuando el investigador delimita con claridad su ruta explicativa y reconoce que otras rutas pueden quedar para futuras investigaciones. Esta práctica también protege la viabilidad empírica, porque evita que el modelo se vuelva excesivamente complejo antes de contar con datos suficientes. La selección de una ruta no implica negar otras, sino concentrar el análisis en aquella que mejor responde al problema y al propósito del estudio (Hair et al., 2021).

El investigador debe cuidar la densidad argumentativa de cada relación. Una relación no debe presentarse con una sola frase, pero tampoco debe repetirse de manera excesiva. Una estructura útil consiste en presentar primero el constructo antecedente, explicar después su vínculo con la variable resultado, justificar la dirección esperada y cerrar con la hipótesis correspondiente. Esta secuencia evita saltos lógicos. Por ejemplo, antes de proponer que las capacidades digitales influyen en el desempeño innovador, debe explicarse cómo permiten mejorar procesos, integrar información, aprender del entorno y generar soluciones. Solo después puede formularse la hipótesis. Así, la hipótesis aparece como consecuencia natural del argumento. En términos pedagógicos, esto es crucial: el investigador debe aprender que una hipótesis no se inventa, sino que **se deriva**. El marco relacional enseña a construir relaciones con argumentación suficiente, sin depender de que el software valide posteriormente una conexión débil. Una relación bien argumentada es defendible incluso antes de conocer su resultado estadístico. Por ello, el marco relacional debe tener una lógica discursiva clara: presentar, conectar, justificar y derivar (Chin, 1998).

El marco relacional debe conservar ortogonalidad interna respecto a los capítulos posteriores. En este tema se explica cómo la teoría justifica relaciones; no conviene desarrollar todavía en profundidad la medición de constructos, los indicadores, la validez convergente, la validez discriminante o la evaluación estructural. Es suficiente señalar que las relaciones deberán ser medibles y evaluables más adelante. Si aquí se agotan los criterios técnicos, se debilita la progresión pedagógica del libro. Por ello, el tema debe concentrarse en la **lógica relacional**: selección de variables, función de constructos, dirección de vínculos, mecanismos y condiciones. Los capítulos posteriores profundizarán en constructos, indicadores y evaluación del modelo. Esta distribución evita repeticiones y permite que el lector avance gradualmente. La ortogonalidad no significa aislar los temas, sino distribuirlos de manera creciente y coherente. El marco relacional prepara el terreno, pero no debe resolver todo el proceso metodológico. Su papel es construir argumentos; la medición y la evaluación vendrán después. De esta manera, el libro conserva una progresión

metodológica clara y evita anticipar prematuramente contenidos técnicos que deben desarrollarse con mayor profundidad en capítulos posteriores (Hair et al., 2019).

La teoría opera también como criterio de exclusión. En muchos casos, el rigor no consiste en agregar más variables, sino en justificar por qué ciertas variables no se incluyen. Por ejemplo, si el estudio se centra en capacidades digitales y aprendizaje organizacional, puede excluir liderazgo, cultura o recursos financieros porque no forman parte del vacío específico abordado. Esta exclusión debe ser razonada. El investigador puede reconocer que esos factores son relevantes, pero explicar que exceden el alcance del modelo. Esto evita críticas por omisión aparente y fortalece la delimitación. Todo modelo deja variables fuera; lo importante es que esa decisión sea coherente con la pregunta. La teoría ayuda a definir fronteras. Un marco relacional maduro no pretende explicarlo todo, sino explicar bien una parte del fenómeno. Esa delimitación permite construir hipótesis más claras, seleccionar indicadores más adecuados y mantener un modelo viable. La exclusión justificada es una señal de dominio conceptual, no una debilidad. Un investigador principiante suele querer incluir demasiado; un investigador formado aprende a delimitar con precisión qué relaciones pertenecen al modelo y cuáles deben quedar fuera por razones de foco, coherencia o viabilidad (Gefen et al., 2000).

El marco relacional debe articular una contribución esperada. Si la teoría solo repite relaciones ya conocidas sin adaptación, mecanismo o contexto relevante, la contribución puede ser limitada. En cambio, el marco relacional puede aportar al proponer una conexión poco explorada, aclarar un mecanismo, distinguir constructos confundidos o probar una relación en un contexto significativo. La contribución no necesariamente implica crear una nueva teoría; puede consistir en mejorar la estructura explicativa de un fenómeno. Por ejemplo, incorporar aprendizaje organizacional como mediador entre capacidades digitales y desempeño innovador puede aportar si permite comprender un proceso antes subestimado. La contribución debe estar conectada con el vacío identificado. Si el vacío y el marco relacional no coinciden, el modelo pierde fuerza. Por ello, cada relación debe ayudar a sostener una contribución específica, no solo aumentar el número de hipótesis. En un modelo SEM, la contribución se construye desde la lógica relacional, no únicamente desde los resultados obtenidos. Incluso si una relación no resulta significativa, puede aportar conocimiento si fue formulada con claridad y permite discutir límites, condiciones o diferencias contextuales. La contribución, por tanto, nace de un marco relacional bien pensado (Hair et al., 2021).

La teoría debe entenderse como una herramienta de construcción propia. El investigador no debe copiar la literatura ni reproducir modelos previos sin adaptación; debe organizar los conceptos en una arquitectura relacional coherente con su problema. Esto implica seleccionar constructos, asignar funciones, justificar direcciones, delimitar relaciones y preparar hipótesis. El marco relacional es una construcción intelectual del investigador, no una compilación de definiciones. Antes de abrir SmartPLS, el investigador debe ser capaz de defender cada relación del modelo con argumentos. Si no puede explicar por qué una flecha existe, el software no

resolverá esa debilidad. El modelo SEM empieza cuando la teoría se convierte en relaciones claras, justificadas y medibles. Solo entonces tiene sentido avanzar hacia los temas siguientes, donde se precisarán las variables dependientes, explicativas, mediadoras y moderadoras con mayor detalle. La idea central es que **la teoría no se copia: se organiza relacionalmente**. Esta comprensión cambia la forma de diseñar investigación: el investigador deja de buscar variables para llenar un modelo y comienza a construir relaciones para responder un problema (Chin, 1998).

Variable dependiente y variables explicativas

Después de delimitar el fenómeno investigable, el siguiente paso consiste en traducirlo en **variables, constructos e indicadores observables**. Esta transición es decisiva porque permite que una idea ya problematizada pueda convertirse en un modelo susceptible de análisis empírico. En SEM y PLS-SEM, el investigador no trabaja únicamente con conceptos generales, sino con constructos que deben ser definidos, organizados y medidos de manera consistente. Por ello, el tema 3.2 no se limita a nombrar variables; introduce los primeros **criterios de medición**, porque en este punto el fenómeno comienza a transformarse en instrumento, escala e indicadores. A diferencia del tema 3.1, donde el propósito era delimitar conceptualmente el fenómeno, aquí ya resulta pertinente explicar qué se medirá, cómo se medirá y bajo qué criterios mínimos podrá considerarse que la medición es aceptable. **Sin una medición adecuada, el modelo estructural pierde sustento**, porque las relaciones entre constructos solo pueden interpretarse correctamente si los constructos están representados por indicadores válidos y confiables (Hair et al., 2019).

Una variable es una característica que puede asumir distintos valores entre unidades de análisis. En ciencias de la administración, las variables pueden referirse a percepciones, actitudes, capacidades, comportamientos, resultados organizacionales, condiciones institucionales o prácticas de gestión. Sin embargo, en SEM es común trabajar con **constructos latentes**, es decir, conceptos que no pueden observarse directamente, pero que se infieren mediante indicadores. Por ejemplo, la autoeficacia tecnológica, la cultura de innovación, la confianza, la actitud hacia la inteligencia artificial, el aprendizaje organizacional o la orientación sostenible no se observan de forma directa; se miden mediante ítems diseñados para captar sus manifestaciones empíricas. **El constructo representa la dimensión conceptual; el indicador representa su expresión observable**. Esta diferencia es fundamental porque evita confundir el concepto teórico con la pregunta del cuestionario. Un ítem no es el constructo completo; es solo una manifestación parcial que, junto con otros indicadores, permite estimar la variable latente (Chin, 1998).

En este apartado conviene introducir también la diferencia entre **constructos reflectivos y constructos formativos**, porque de esa decisión depende la forma de evaluar la medición. En un constructo reflectivo, los indicadores son manifestaciones del constructo; por ejemplo, si aumenta la satisfacción laboral, se espera que aumenten varios ítems asociados con satisfacción, bienestar o valoración positiva del

trabajo. En este caso, los indicadores deberían correlacionarse entre sí, porque reflejan una misma dimensión latente. En cambio, en un constructo formativo, los indicadores no son reflejos intercambiables, sino componentes que forman el constructo. Por ejemplo, una capacidad organizacional podría estar formada por recursos humanos, tecnológicos, financieros y estratégicos; eliminar uno de esos componentes podría cambiar el significado del constructo. **La decisión entre medición reflectiva y formativa no es estadística en primer lugar; es conceptual**. El investigador debe preguntarse si los indicadores son consecuencias del constructo o si son componentes que lo integran (Hair et al., 2019).

La medición de los constructos suele realizarse mediante escalas tipo Likert, especialmente en estudios de administración, educación, innovación y comportamiento organizacional. Estas escalas permiten captar percepciones, grados de acuerdo, frecuencia, intensidad o valoración subjetiva. Las escalas de **5 puntos** son útiles cuando se busca facilitar la respuesta y reducir carga cognitiva; las escalas de **7 puntos** permiten mayor sensibilidad y diferenciación entre niveles de respuesta. La elección depende del tipo de población, la complejidad del instrumento y el grado de precisión requerido. Por ejemplo, en poblaciones con menor familiaridad con cuestionarios extensos, una escala de **5** puntos puede ser más clara; en investigaciones académicas con participantes acostumbrados a instrumentos de medición, una escala de **7** puntos puede ofrecer mayor variabilidad. **Lo importante no es elegir la escala más larga, sino la más coherente con el constructo, la población y el objetivo del estudio**. La escala debe mantenerse consistente para evitar confusión en los participantes.

En modelos reflectivos, uno de los primeros criterios de medición corresponde a las **cargas externas** de los indicadores. La carga externa muestra qué tan fuertemente se relaciona cada indicador con el constructo que pretende medir. Como regla orientativa, una carga externa de **.708 o superior** suele considerarse recomendable, porque implica que el indicador comparte una proporción adecuada de varianza con el constructo. Sin embargo, cargas entre **.40 y .70** pueden evaluarse con cautela antes de eliminarse, especialmente si el indicador tiene valor teórico o si su eliminación no mejora la confiabilidad y validez del constructo. Cargas menores a **.40** suelen considerarse problemáticas. **La eliminación de indicadores no debe ser automática; debe valorar simultáneamente el criterio estadístico y la pertinencia conceptual**. Un indicador con carga ligeramente menor puede conservarse si representa una dimensión importante del constructo; en cambio, un indicador con carga baja y débil justificación teórica debería revisarse o eliminarse (Hair et al., 2019).

Otro criterio relevante es la **confiabilidad interna**, que indica si los indicadores de un constructo muestran consistencia entre sí. Tradicionalmente se ha utilizado el **alfa de Cronbach**, cuyo valor mínimo aceptable suele ubicarse en **.70** para investigaciones confirmatorias o aplicadas. En estudios exploratorios, valores cercanos a **.60** pueden considerarse aceptables con cautela, siempre que exista justificación. Sin embargo, el alfa de Cronbach puede ser conservador, porque asume que todos los indicadores contribuyen de manera equivalente al constructo. Por ello, en PLS-SEM también se

recomienda revisar la **confiabilidad compuesta**, cuyo rango deseable suele ubicarse entre **.70 y .95**. Valores menores a **.70** sugieren insuficiente consistencia; valores superiores a .95 pueden indicar redundancia entre indicadores. **Una escala confiable no es aquella que repite la misma pregunta varias veces, sino aquella que capta de manera consistente distintas manifestaciones del mismo constructo** (Hair et al., 2019).

La **validez convergente** permite evaluar si los indicadores realmente convergen en la medición del constructo. En **modelos reflectivos,** el criterio más utilizado es la **varianza media extraída**, conocida como **AVE** por sus siglas en inglés: *Average Variance Extracted*. Un valor de **AVE ≥ .50** indica que el constructo explica al menos la mitad de la varianza de sus indicadores, lo cual se considera un umbral aceptable. Si el AVE es menor a **.50,** puede significar que los indicadores no representan adecuadamente el constructo o que existe demasiada varianza de error. **La validez convergente responde a una pregunta central: los indicadores seleccionados, ¿realmente están midiendo el mismo concepto?**. Este criterio es especialmente importante porque un constructo puede tener buena confiabilidad aparente y, aun así, presentar problemas de convergencia si sus indicadores no se integran conceptualmente de manera suficiente (Fornell & Larcker, 1981).

La **validez discriminante** permite comprobar que un constructo es distinto de los demás constructos del modelo. Esta condición es esencial porque, si dos constructos miden prácticamente lo mismo, sus relaciones estructurales pueden ser artificiales o redundantes. Uno de los criterios más utilizados actualmente es el **HTMT**, por sus siglas en inglés: *Heterotrait-Monotrait Ratio*. Como regla orientativa, un valor **HTMT < .85** se considera un criterio estricto de discriminación, mientras que **HTMT < .90** puede aceptarse en contextos más flexibles o cuando los constructos son conceptualmente cercanos. **La validez discriminante protege la identidad conceptual de cada constructo**. Por ejemplo, actitud hacia la IA, intención de uso y percepción de utilidad pueden estar relacionadas, pero no deben ser indistinguibles. Si los constructos se traslapan excesivamente, el modelo pierde claridad y las hipótesis pueden convertirse en relaciones entre conceptos mal diferenciados (Henseler et al., 2015).

En **modelos formativos,** los indicadores no son reflejos intercambiables del constructo, sino componentes que lo forman. Por ello, cada indicador debe aportar una parte conceptualmente necesaria del dominio de medición. En esta etapa, la revisión principal no es todavía estadística, sino conceptual: el investigador debe verificar si los indicadores representan dimensiones distintas o si repiten la misma idea con variaciones mínimas de redacción. E**n constructos formativos, el problema no es que los indicadores sean diferentes, sino que sean innecesariamente redundantes**. La evaluación técnica de colinealidad mediante **VIF** se desarrolla en el Capítulo 5, dentro del análisis de colinealidad, sesgo de método común y calidad de los indicadores (Diamantopoulos & Winklhofer, 2001; Hair et al., 2021).

La construcción de indicadores debe anticipar posibles redundancias conceptuales. Por ejemplo, si una capacidad organizacional se mide mediante recursos tecnológicos, competencias digitales y madurez digital, el investigador debe

revisar si cada dimensión aporta contenido específico o si algunas están midiendo prácticamente lo mismo. Esta revisión no sustituye la evaluación estadística posterior; su función es depurar la arquitectura conceptual antes de estimar el modelo. Por ello, la definición de indicadores debe apoyarse en la teoría, la claridad semántica de los ítems y la coherencia con el dominio del constructo. La comprobación empírica de colinealidad queda reservada para el Capítulo 5 (Hair et al., 2021).

La definición de indicadores debe mantener correspondencia directa con el constructo que pretende medir. Esto significa que cada ítem debe derivarse de la definición conceptual y no de ocurrencias aisladas. Por ejemplo, si el constructo es "intención de uso académico responsable de IA generativa", los indicadores no deberían limitarse a preguntar si el estudiante usa herramientas de IA, sino si planea usarlas con criterios académicos, éticos, verificables y alineados con objetivos de aprendizaje. Si el constructo es "cultura de innovación sostenible", los indicadores deben captar prácticas organizacionales orientadas a nuevas ideas, mejora continua, sostenibilidad y generación de valor social o ambiental. **Un buen indicador no solo pregunta algo relacionado con el tema; expresa una parte específica del constructo**. Esta precisión permite que el cuestionario sea coherente con el modelo y evita que las mediciones sean superficiales o ambiguas.

La redacción de los indicadores debe cuidar claridad, unidimensionalidad y neutralidad. Un ítem debe medir una sola idea a la vez. Por ejemplo, una pregunta como "en mi organización se promueve la innovación y se capacita al personal en sostenibilidad" combina dos contenidos distintos: promoción de innovación y capacitación en sostenibilidad. Si el participante está de acuerdo con uno, pero no con el otro, su respuesta será ambigua. Por ello, conviene separar ambos contenidos en indicadores distintos. Además, los ítems deben evitar lenguaje técnico innecesario, juicios de valor, dobles negaciones o formulaciones que induzcan la respuesta. **La calidad del indicador depende tanto de su fundamento teórico como de su claridad lingüística**. En estudios aplicados, un instrumento bien redactado reduce errores de comprensión, mejora la calidad de los datos y fortalece la validez de los resultados.

También es recomendable que cada constructo cuente con un número suficiente de indicadores. En **modelos reflectivos,** suele sugerirse trabajar con al menos **tres indicadores por constructo**, aunque en algunos casos pueden utilizarse más para captar mejor la dimensión conceptual. Un número excesivo de ítems puede volver pesado el cuestionario; un número insuficiente puede limitar la confiabilidad y la validez. En modelos formativos, el número de indicadores depende de las dimensiones que forman el constructo; no se busca necesariamente alta consistencia interna, sino cobertura conceptual. **La cantidad de indicadores debe responder a la complejidad del constructo, no a una regla mecánica**. Por ejemplo, un constructo simple puede medirse con pocos indicadores bien diseñados, mientras que un constructo multidimensional requerirá mayor cobertura para evitar omitir componentes relevantes.

La medición también debe anticipar la relación entre constructos e hipótesis. Si una hipótesis plantea que la autoeficacia tecnológica influye en la intención de uso de IA

generativa, ambos constructos deben estar medidos con indicadores que representen adecuadamente esa relación. Si la autoeficacia se mide de forma genérica y la intención de uso se mide solo como frecuencia de uso, la hipótesis puede perder precisión. **La hipótesis solo puede evaluarse correctamente si los constructos involucrados fueron operacionalizados de manera coherente**. Por esta razón, el diseño del instrumento debe dialogar con el modelo estructural. No se trata de redactar preguntas y después buscar cómo conectarlas, sino de definir constructos, formular relaciones y construir indicadores alineados con esa arquitectura conceptual.

En este punto, los límites y niveles de medición deben entenderse como **criterios orientativos**, no como reglas absolutas. Los valores recomendados ayudan a evaluar la calidad de la medición, pero no sustituyen el juicio teórico. Por ejemplo, una carga externa ligeramente inferior al umbral puede conservarse si el indicador es conceptualmente indispensable; un alfa demasiado alto puede indicar redundancia; un HTMT cercano al límite puede requerir revisión conceptual antes de eliminar constructos; un VIF elevado puede revelar traslape entre indicadores. **Los umbrales estadísticos ayudan a diagnosticar, pero la decisión final debe integrar teoría, método y sentido sustantivo**. Esta postura evita una lectura mecánica de SEM o PLS-SEM y fortalece la calidad académica del modelo.

De esta manera, el tema introduce los primeros límites técnicos del capítulo, pero lo hace en el lugar adecuado: el paso de los constructos a los indicadores. Aquí corresponde explicar cargas externas, confiabilidad, validez convergente, validez discriminante y colinealidad, porque todos estos criterios se relacionan con la calidad de la medición. En cambio, los criterios del modelo estructural, como R^2 , f^2 y Q^2 , corresponden mejor al tema 3.3; y los niveles de significancia, valores **t**, valores **p** e intervalos de confianza corresponden al tema 3.4. **Esta distribución evita repeticiones y permite que el capítulo avance de manera ordenada: primero se delimita el fenómeno, después se mide, luego se evalúa la lógica del modelo y finalmente se contrastan hipótesis**.

Panorama de las técnicas SEM y lógica de modelación estructural

El modelado de ecuaciones estructurales, conocido como SEM, debe presentarse primero como una familia amplia de técnicas y no como una técnica única. Esta precisión es indispensable porque, en la práctica, muchos investigadores asocian SEM solamente con algunos programas —por ejemplo, **AMOS, LISREL, EQS, Mplus, SmartPLS o ADANCO**—, cuando en realidad estos programas son herramientas operativas para implementar distintas lógicas de modelación. SEM permite representar relaciones entre constructos teóricos, variables observadas, errores de medición y trayectorias estructurales. Por ello, el punto de partida no debe ser el software, sino el tipo de problema que se desea modelar: si el estudio busca confirmar una teoría, explicar relaciones entre constructos, predecir resultados, comparar grupos, analizar mediaciones, estudiar moderaciones o evaluar cambios

longitudinales. **Henseler (2017), explica que SEM permite modelar relaciones entre constructos teóricos y distinguir entre los constructos y sus mediciones observables; además, diferencia los enfoques basados en covarianzas de los enfoques basados en varianza.** Esta idea es fundamental para el capítulo, porque permite mostrar que **el software no define el método; el método define qué software resulta más apropiado**. Así, programas como **AMOS, LISREL, EQS, Mplus, lavaan y Stata SEM** suelen asociarse con modelos basados en covarianzas, mientras que **SmartPLS, ADANCO, WarpPLS, PLS-Graph, SEMinR, cSEM y semPLS** se vinculan con enfoques basados en varianza, componentes y PLS-SEM.

Una primera técnica relevante dentro del universo SEM es el análisis de trayectoria o *path analysis*. Esta técnica puede entenderse como un antecedente directo del modelado estructural moderno, porque permite representar relaciones causales hipotéticas entre variables observadas mediante diagramas de flechas. A diferencia de los modelos SEM completos, el análisis de trayectoria no necesariamente trabaja con variables latentes medidas por múltiples indicadores, sino con variables observadas que se organizan dentro de una red de dependencias. Su valor pedagógico es alto porque introduce conceptos esenciales: **variable exógena, variable endógena, efecto directo, efecto indirecto, efecto total, mediación y secuencia causal**. Por ejemplo, en un estudio sobre innovación, el investigador puede proponer que la orientación emprendedora influye en la capacidad de absorción y que esta, a su vez, influye en el desempeño innovador. En términos de software, el análisis de trayectoria puede trabajarse en **AMOS**, por su interfaz gráfica; en **LISREL** y **EQS**, por su tradición en ecuaciones estructurales; en **Mplus**, por su capacidad para modelos complejos; en **Lavaan**, dentro de R, por su reproducibilidad; y en **Stata SEM**, por su integración con análisis estadísticos y econométricos. También puede aproximarse mediante regresiones sucesivas en **SPSS**, **R** o **Jamovi**, aunque los programas SEM permiten evaluar el sistema de relaciones de manera más integrada. **El análisis de trayectoria enseña que un modelo no es una suma aislada de regresiones, sino una arquitectura relacional donde las variables cumplen funciones distintas dentro de un sistema explicativo.**

Otra técnica fundamental es el análisis factorial confirmatorio, conocido como CFA, porque se concentra en el modelo de medición. Su propósito principal es evaluar si los indicadores observados representan adecuadamente los constructos latentes propuestos por la teoría. En ciencias sociales, administración, innovación, educación y marketing, muchos fenómenos no se observan directamente: confianza, actitud, satisfacción, compromiso, capacidad innovadora, aprendizaje organizacional o sostenibilidad son constructos que requieren ser inferidos a partir de ítems, escalas o indicadores. Por ello, antes de estimar relaciones estructurales, el investigador debe demostrar que sus constructos están correctamente medidos. El CFA permite revisar si los indicadores cargan en el factor esperado, si existe consistencia interna, si hay validez convergente y si los constructos son suficientemente distintos entre sí. En términos de software, el CFA suele implementarse en **AMOS**, **LISREL**, **EQS**, **Mplus**, **lavaan**, **JASP** y **Jamovi**. **AMOS** facilita la construcción visual del modelo; **LISREL** y **EQS** tienen una fuerte tradición histórica en estructuras de covarianza; **Mplus** es

especialmente útil para modelos complejos o con variables categóricas; y **Lavaan** ofrece trazabilidad mediante sintaxis en R. En el capítulo, esta técnica debe aparecer como paso clave porque **no es metodológicamente defendible probar hipótesis entre constructos si antes no se ha demostrado que esos constructos fueron medidos con validez suficiente**. Churchill (1979) ya advertía que la calidad del conocimiento por ejemplo, en marketing, depende de desarrollar mejores medidas de los constructos utilizados por los investigadores.

Dentro de SEM también deben diferenciarse los modelos reflectivos, formativos y compuestos, porque no todos los indicadores se relacionan del mismo modo con el constructo. En un **modelo reflectivo,** el constructo se considera la causa de sus indicadores; por ejemplo, una actitud favorable hacia una tecnología se manifiesta en respuestas positivas a varios ítems. En un **modelo formativo,** los indicadores forman el constructo; por ejemplo, escolaridad, ingreso y ocupación pueden formar un índice socioeconómico. En un **modelo compuesto**, los indicadores se combinan como componentes constitutivos de una entidad conceptual, lo cual es frecuente en estudios sobre capacidades, recursos, artefactos, desempeño o innovación. Esta distinción es decisiva porque **una mala especificación del modelo de medición puede distorsionar todo el modelo estructural**. Los **modelos reflectivos** suelen trabajarse con **AMOS, LISREL, EQS, Mplus y Lavaan**, especialmente cuando se asume una lógica de factor común. Los **modelos formativos** y **compuestos** suelen asociarse con **SmartPLS, ADANCO, WarpPLS, SEMinR y cSEM**, porque estos programas permiten trabajar con indicadores causales, pesos externos, colinealidad y constructos compuestos. Sin embargo, también pueden especificarse modelos formativos avanzados en **Mplus** o **Lavaan**, siempre que el investigador domine la sintaxis. La decisión no debe depender del programa, sino de la teoría: **los indicadores pueden ser manifestaciones, causas o componentes del constructo**, y cada caso exige criterios de evaluación diferentes. Diamantopoulos y Winklhofer (2001) plantean precisamente la importancia de la construcción de índices con indicadores formativos como alternativa al desarrollo tradicional de escalas.

Los modelos MIMIC, es decir, *multiple indicators multiple causes*, amplían la lógica de medición porque permiten combinar indicadores y causas observadas de un constructo latente. Estos modelos son útiles cuando el investigador desea analizar un constructo que no solo se mide mediante indicadores, sino que también es explicado por variables antecedentes. Por ejemplo, una actitud latente puede estar medida por varios ítems y, al mismo tiempo, ser explicada por edad, experiencia, nivel educativo o exposición previa a una tecnología. En este tipo de modelos, algunas variables funcionan como causas observadas del constructo y otras como indicadores de su manifestación empírica. Su importancia dentro del panorama SEM es que muestran que la relación entre teoría y medición puede ser más compleja que una simple escala reflectiva. En términos de software, los modelos MIMIC suelen implementarse en **Mplus**, **LISREL**, **EQS**, **AMOS** y **Lavaan**, debido a su tradición en modelos de variables latentes y estructuras de covarianza. También pueden aproximarse en algunos entornos de modelos compuestos, pero su formulación clásica pertenece más claramente al marco de SEM basado en factores comunes. **La**

enseñanza metodológica central es que el investigador debe distinguir entre variables que miden un constructo y variables que lo explican. Si se confunden ambas funciones, el modelo puede presentar errores conceptuales graves. Henseler (2017) señala que los modelos basados en varianza pueden manejar distintos tipos de modelos de medición, incluyendo factores comunes, compuestos y medición causal-formativa, lo cual refuerza la necesidad de especificar correctamente la naturaleza de cada constructo.

Los modelos multigrupo y los análisis de invariancia de medición son indispensables cuando el investigador desea comparar poblaciones, contextos o segmentos. En la investigación aplicada es común preguntar si un modelo funciona igual en hombres y mujeres, estudiantes de distintas carreras, empresas grandes y pequeñas, sectores industriales, países, regiones o generaciones. Sin embargo, antes de comparar coeficientes estructurales entre grupos, debe verificarse que los constructos se midan de manera equivalente. Si un constructo como confianza, satisfacción, actitud, capacidad digital o innovación no tiene el mismo significado empírico entre grupos, las diferencias encontradas pueden deberse a problemas de medición y no a diferencias reales. En **CB-SEM**, la invariancia suele analizarse en **AMOS, LISREL, EQS, Mplus y lavaan**, mediante pruebas progresivas de invariancia configuracional, métrica y escalar. **En PLS-SEM**, se utilizan procedimientos como **MICOM**, disponibles especialmente en **SmartPLS**, así como alternativas en **ADANCO**, **cSEM** y **SEMinR**. Los análisis multigrupo también se realizan en **SmartPLS**, **ADANCO**, **WarpPLS**, **Mplus** y **lavaan**. **Comparar grupos sin evaluar invariancia puede llevar a inferencias equivocadas**, porque se podrían atribuir a diferencias estructurales lo que en realidad proviene de una medición no equivalente. Henseler, Ringle y Sarstedt (2016) abordan precisamente la prueba de invariancia de medición de compuestos mediante PLS, mostrando la importancia de asegurar comparabilidad antes de interpretar diferencias entre grupos.

Los modelos de mediación y moderación ocupan un lugar central en SEM porque permiten pasar de relaciones simples a explicaciones más sofisticadas. La mediación responde a la pregunta por el mecanismo: cómo o por qué una variable independiente influye en una variable dependiente. Por ejemplo, la transformación digital puede influir en el desempeño innovador a través del aprendizaje organizacional. **La moderación** responde a la pregunta por la condición: cuándo, para quién o bajo qué circunstancias una relación se fortalece, se debilita o cambia de dirección. Por ejemplo, la relación entre capacidades digitales e innovación puede ser más fuerte cuando la organización opera en un entorno altamente competitivo. Estos modelos pueden estimarse desde **CB-SEM** en **AMOS, LISREL, EQS, Mplus, Lavaan y Stata SEM**, y desde **PLS-SEM** en **SmartPLS, ADANCO, WarpPLS, SEMinR y cSEM**. También existen herramientas complementarias como **PROCESS** en SPSS o R, útiles para modelos de mediación y moderación con variables observadas, aunque no sustituyen completamente a SEM cuando se trabaja con constructos latentes. **La mediación y la moderación no deben entenderse como adornos estadísticos, sino como decisiones teóricas que refinan la explicación del fenómeno.** Nitzl, Roldan y Cepeda (2016) enfatizan que el análisis de mediación en PLS *path* modeling

ayuda a discutir modelos más sofisticados y a comprender mejor los mecanismos de relación entre constructos.

Los modelos de segundo orden o modelos jerárquicos permiten representar constructos multidimensionales dentro de SEM. Esta técnica es especialmente útil cuando un constructo amplio no puede ser captado por una sola dimensión. Por ejemplo, la transformación digital puede integrar infraestructura tecnológica, cultura digital, habilidades humanas y rediseño de procesos; la sostenibilidad empresarial puede incluir dimensiones económicas, sociales y ambientales; la innovación puede diferenciarse en innovación de producto, proceso, organización o marketing. En **CB-SEM**, los modelos jerárquicos pueden estimarse en **AMOS, LISREL, EQS, Mplus y lavaan**; en **PLS-SEM**, suelen trabajarse en **SmartPLS, ADANCO, WarpPLS, SEMinR y cSEM**, mediante estrategias como el enfoque de indicadores repetidos, el enfoque de dos etapas o el enfoque híbrido. **El modelo de segundo orden no debe usarse solo para hacer más complejo el análisis, sino cuando existe una justificación teórica para entender un constructo como multidimensional.** Si las dimensiones no pertenecen a un dominio común, el constructo jerárquico será artificial; si la teoría sí lo justifica, SEM permite representar fenómenos organizacionales complejos de manera más fiel. Henseler (2017) destaca que los constructos pueden asumir naturalezas distintas —factores comunes, compuestos o medición causal-formativa—, lo cual resulta especialmente importante cuando se modelan estructuras jerárquicas o multidimensionales.

Los modelos de crecimiento latente y los modelos longitudinales extienden SEM hacia el análisis del cambio en el tiempo. Mientras muchos modelos estructurales transversales responden qué variable explica a otra en un momento determinado, los modelos de crecimiento latente permiten analizar trayectorias: cuál es el punto de partida de un fenómeno, cómo cambia, a qué ritmo cambia y qué variables explican diferencias en esa evolución. En educación, estos modelos pueden analizar el desarrollo de competencias a lo largo de varios semestres; en innovación, la evolución de capacidades tecnológicas; en comportamiento organizacional, cambios en compromiso o satisfacción; y en estudios de adopción tecnológica, transformaciones en actitudes o uso de plataformas. El software más asociado con estos modelos es **Mplus**, debido a su potencia para modelos longitudinales, multinivel y de variables latentes; también pueden trabajarse en **lavaan**, **LISREL**, **EQS**, **AMOS** y **Stata SEM**, dependiendo de la complejidad. **Su importancia es que permiten estudiar procesos, no solo estructuras estáticas.** En lugar de comparar dos medias en momentos distintos, los modelos de crecimiento latente modelan la trayectoria completa y permiten identificar factores que explican tanto el nivel inicial como el cambio. Así, SEM se convierte en una herramienta para estudiar transformación, aprendizaje, adopción, maduración o deterioro en fenómenos sociales y organizacionales. Esta ampliación resulta coherente con la visión de SEM como familia metodológica capaz de representar relaciones complejas entre constructos y mediciones observables.

Finalmente, dentro de esta primera parte debe mencionarse que existen técnicas basadas en componentes y varianza más allá de PLS-SEM, aunque PLS-SEM sea la más difundida. Entre ellas se encuentran **GSCA**, **IGSCA**, regresión sobre puntuaciones agregadas, análisis de componentes principales, enfoques de variables canónicas generalizadas y **PLSc** o consistent PLS. **GSCA** suele asociarse con **GSCA Pro** y software especializado; los análisis de componentes principales pueden trabajarse en **SPSS, R, Python, Stata, Jamovi y JASP**; la regresión con *sum scores* puede realizarse en **SPSS, R, Stata o Jamovi**; y PLSc se ha vinculado con **ADANCO, SmartPLS y cSEM**. Estas alternativas muestran que el campo SEM no se limita a CB-SEM y PLS-SEM, sino que incluye diversas formas de representar constructos, factores, compuestos e índices. Sin embargo, también obligan a la prudencia: usar componentes o puntuaciones agregadas puede ser útil, pero puede ignorar errores de medición si no se justifica adecuadamente. Dijkstra y Henseler (2015) explican que existen dos grandes familias predominantes en SEM —basada en covarianzas y basada en varianza—, y que dentro de esta última se encuentran varias técnicas, entre ellas PLS, GSCA, regresión sobre componentes y otros métodos. **Con este panorama, la segunda parte puede concentrarse en CB-SEM y PLS-SEM, no porque sean las únicas técnicas, sino porque son las más conocidas y utilizadas en investigación aplicada con constructos latentes.** Véase la **Tabla 3.1**

Tabla 3.1. Técnicas SEM y software asociado

Técnica SEM	Propósito principal	Software comúnmente asociado
Análisis de trayectoria / *Path* analysis	Es un antecedente directo de SEM. Modela relaciones causales hipotéticas entre variables observadas, sin necesariamente incluir constructos latentes. Permite estimar efectos directos, indirectos y totales. Es útil cuando el investigador ya tiene variables medidas directamente y desea representar una cadena relacional, por ejemplo: capacidades digitales → aprendizaje organizacional → innovación.Evaluar relaciones directas, indirectas y totales entre variables observadas	AMOS, LISREL, EQS, Mplus, lavaan, Stata SEM
Análisis factorial confirmatorio / CFA	Evalúa el modelo de medición. Su propósito es confirmar si los indicadores observados representan adecuadamente los constructos latentes propuestos por la teoría. Es central para revisar cargas factoriales, validez convergente, validez discriminante y consistencia interna. Antes de probar hipótesis estructurales, el investigador debe demostrar que los constructos están bien medidos. Churchill advierte que la calidad del conocimiento depende de la calidad de las medidas usadas para estudiar los constructos.Confirma la estructura de medición de constructos latentes	AMOS, LISREL, EQS, Mplus, lavaan, JASP, Jamovi
CB-SEM	Es el modelado de ecuaciones estructurales basado en covarianzas. Busca evaluar si el modelo teórico reproduce adecuadamente la matriz de covarianzas observada. Se usa cuando el objetivo es confirmar teoría, evaluar ajuste global y trabajar con modelos reflectivos bien fundamentados. Hair et al. indican que CB-SEM es	AMOS, LISREL, EQS, Mplus, lavaan, Stata SEM

Técnica SEM	Propósito principal	Software comúnmente asociado
	adecuado cuando el objetivo es prueba y confirmación teórica, cuando se requiere bondad de ajuste global o cuando los errores requieren especificación adicional. Confirma modelos teóricos mediante ajuste de covarianzas	
PLS-SEM	Es el modelado de ecuaciones estructurales por mínimos cuadrados parciales. Se basa en varianza y componentes, y busca maximizar la varianza explicada de los constructos endógenos. Es útil cuando el estudio tiene orientación predictiva, modelos complejos, constructos formativos o compuestos, teoría en desarrollo o necesidad de obtener puntuaciones latentes. Hair et al. describen PLS-SEM como un enfoque causal-predictivo que permite estimar modelos complejos sin imponer supuestos estrictos de distribución. Explica y predice constructos endógenos mediante varianza explicada	SmartPLS, ADANCO, WarpPLS, PLS-Graph, SEMinR, cSEM
PLSc / consistent PLS	Es una extensión de PLS-SEM diseñada para corregir problemas de consistencia cuando PLS se aplica a modelos reflectivos de factores comunes. Su propósito es aproximar mejor los parámetros cuando el constructo se entiende como factor común y no como compuesto. En términos prácticos, PLS tradicional resulta más coherente con modelos de compuestos, mientras que PLSc se recomienda cuando el investigador desea estimar modelos de factor común o modelos mixtos que combinan factores y compuestos.	SmartPLS, ADANCO, cSEM
Modelos formativos	Modela constructos formados por indicadores causales o componentes. En estos modelos, los indicadores forman o causan el constructo. Por ejemplo, infraestructura, talento digital, procesos automatizados y cultura tecnológica pueden formar una capacidad digital organizacional. Aquí no se espera necesariamente alta correlación entre indicadores, porque cada uno representa una parte distinta del constructo. Hair et al. señalan que PLS-SEM es especialmente pertinente cuando el modelo incluye constructos formativos.	SmartPLS, ADANCO, WarpPLS, Mplus, lavaan
Modelos compuestos	Representa constructos como combinaciones de componentes ponderadas de indicadores. Son comunes cuando el fenómeno se entiende como artefacto, capacidad, índice o configuración de componentes. A diferencia del factor común, el compuesto no presupone una variable latente subyacente que causa todos los indicadores. Henseler et al. distinguen entre factores comunes, indicadores causales y modelos compuestos como tres formas de medición en SEM.	SmartPLS, ADANCO, cSEM, SEMinR
Modelos MIMIC	Analizar constructos con indicadores y causas observadas. MIMIC significa multiple indicators multiple causes. Son modelos donde un constructo latente tiene indicadores que lo miden y variables observadas que lo explican. Permiten integrar medición y causalidad en una misma estructura. Por ejemplo, una actitud puede estar	Mplus, LISREL, EQS, AMOS, lavaan

Técnica SEM	Propósito principal	Software comúnmente asociado
	medida por ítems y explicada por edad, experiencia o nivel educativo	
Modelos de mediación	Evalua mecanismos indirectos entre variables. Analizan mecanismos explicativos. Una variable mediadora explica cómo o por qué una variable independiente influye en una dependiente. Por ejemplo: liderazgo transformacional → aprendizaje organizacional → innovación. La mediación permite pasar de una relación simple a una explicación causal más sofisticada.	AMOS, LISREL, EQS, Mplus, SmartPLS, lavaan
Modelos de moderación	Evaluar si una relación cambia según una condición. Analizan condiciones bajo las cuales una relación cambia en intensidad o dirección. Una variable moderadora responde a la pregunta: cuándo, para quién o bajo qué condiciones ocurre una relación. Por ejemplo, la turbulencia ambiental puede fortalecer o debilitar la relación entre capacidades digitales e innovación.	SmartPLS, AMOS, Mplus, lavaan, PROCESS en SPSS/R
Modelos multigrupo	Permiten comparar si un modelo estructural funciona igual o diferente entre grupos: hombres/mujeres, empresas grandes/pequeñas, países, generaciones, sectores o niveles educativos. Su utilidad es identificar si las relaciones estructurales son equivalentes o si cambian según el contexto.	AMOS, LISREL, EQS, Mplus, SmartPLS, ADANCO, lavaan
Invariancia de medición	Verifica si un constructo se mide de manera equivalente entre grupos. Es indispensable antes de comparar coeficientes estructurales. Si no hay invariancia, las diferencias entre grupos pueden deberse a fallas de medición y no a diferencias reales. Henseler et al. proponen MICOM para evaluar invariancia en modelos compuestos dentro de PLS.	Mplus, LISREL, lavaan, AMOS, SmartPLS
Modelos de segundo orden / jerárquicos	Representan constructos multidimensionales. Por ejemplo, la transformación digital puede tener dimensiones tecnológicas, culturales, humanas y estratégicas. Estos modelos permiten que un constructo superior se explique o refleje mediante dimensiones de primer orden. Hair et al. señalan que PLS-SEM permite especificar elementos avanzados como constructos de orden superior.	SmartPLS, AMOS, LISREL, Mplus, Lavaan
Modelos de crecimiento latente	Son modelos longitudinales que analizan cambio en el tiempo. Estiman el punto inicial, la pendiente de cambio y los factores que explican diferencias en trayectorias. Son útiles para estudiar evolución de competencias, adopción tecnológica, aprendizaje, desempeño o actitudes en varios momentos.	Mplus, lavaan, LISREL, EQS, AMOS
Modelos de ecuaciones simultáneas	Analizan sistemas donde las variables pueden influirse mutuamente. Son útiles cuando existen relaciones recíprocas, endogeneidad o causalidad circular. Por ejemplo, innovación puede mejorar desempeño, pero el desempeño también puede generar recursos para innovar.	LISREL, Mplus, Stata, R, EQS

Técnica SEM	Propósito principal	Software comúnmente asociado
GSCA	Generalized Structured Component Analysis es una técnica SEM basada en componentes. Permite estimar modelos estructurales usando componentes en lugar de factores comunes. Es alternativa a PLS-SEM cuando se desea una lógica de componentes con criterios propios de estimación. Dijkstra y Henseler mencionan GSCA como una de las técnicas SEM basadas en varianza disponibles junto con PLS y otros métodos	GSCA Pro, GeSCA, R packages especializados
Regresión con sum scores	Consiste en sumar o promediar ítems para crear puntuaciones agregadas y luego analizarlas con regresión. Es una estrategia sencilla, pero menos rigurosa que SEM porque no modela explícitamente el error de medición. Puede ser útil en análisis preliminares o cuando las escalas ya están muy consolidadas, pero no sustituye plenamente a SEM.	SPSS, Stata, R, Jamovi, JASP
Análisis de componentes principales / PCA	Es una técnica de reducción de datos que transforma variables correlacionadas en componentes lineales. No es SEM en sentido estricto, pero se relaciona con enfoques de componentes y puede usarse para exploración, reducción dimensional o construcción preliminar de índices. No debe confundirse con CFA, porque PCA no confirma un modelo teórico de medición latente.	SPSS, R, Python, Stata, Jamovi, JASP

Fuentre: recopilación y elaboración propia

Después de definir el fenómeno investigable, las variables, los constructos y los indicadores, el investigador debe avanzar hacia la construcción de la **lógica del modelo estructural**. En esta fase, el interés ya no se concentra únicamente en determinar si los indicadores representan adecuadamente a los constructos, sino en comprender **cómo se relacionan los constructos entre sí**, qué variables funcionan como antecedentes, cuáles actúan como consecuencias, qué relaciones tienen sentido teórico y qué capacidad tiene el modelo para explicar o predecir el fenómeno central. En SEM, esta transición es decisiva porque permite pasar del plano de la medición al plano de la relación estructural. Un modelo no se justifica por la cantidad de flechas que contiene, sino por la **coherencia conceptual de sus rutas**, la pertinencia de sus constructos y la claridad con que expresa una arquitectura explicativa o predictiva. Por ello, en este apartado deben introducirse los criterios que permiten valorar la lógica estructural del modelo, tales como R^2 , f^2 , Q^2 , **VIF, efectos directos, efectos indirectos, efectos totales, significancia de rutas y, cuando corresponda al enfoque CB-SEM, índices de ajuste global como χ^2, gl, p, NFI, NNFI/TLI, CFI, RMSEA y SRMR**. Estos criterios no sustituyen la teoría; funcionan como herramientas para evaluar si la propuesta conceptual tiene consistencia empírica y utilidad interpretativa. **La lógica del modelo debe construirse antes del software, porque el análisis estadístico solo evalúa una estructura que ya debió ser razonada conceptualmente** (Hair et al., 2019).

La primera distinción necesaria es entre modelo de medición y modelo estructural. El modelo de medición responde a la pregunta: ¿los indicadores

representan adecuadamente los constructos? En cambio, el modelo estructural responde a una pregunta distinta: ¿los constructos se relacionan entre sí de acuerdo con la lógica conceptual propuesta? Por ejemplo, si el investigador estudia la adopción académica de inteligencia artificial generativa, el modelo de medición revisa si los ítems de autoeficacia, actitud, percepción de utilidad o intención de uso captan correctamente cada constructo. El modelo estructural, en cambio, analiza si la autoeficacia influye en la actitud, si la actitud influye en la intención o si la percepción de utilidad contribuye a explicar el comportamiento esperado. **Esta diferencia evita confundir la calidad de los indicadores con la calidad de las relaciones entre constructos**. Un instrumento puede tener buena confiabilidad, pero si las relaciones estructurales carecen de lógica teórica, el modelo será débil. A la inversa, una propuesta teórica puede ser interesante, pero si los constructos no están bien medidos, las rutas estructurales perderán valor interpretativo. Por eso, la evaluación del modelo estructural debe realizarse después de asegurar una medición aceptable, pero sin olvidar que la estructura de relaciones depende de la teoría, del problema de investigación y de la finalidad analítica del estudio. **Primero se mide con rigor; después se interpreta la red de relaciones** (Chin, 1998).

La lógica del modelo puede tener una orientación explicativa, predictiva o **mixta**. Un modelo explicativo busca responder por qué ocurre un fenómeno, mediante qué antecedentes, con qué mecanismos y bajo qué condiciones. En este caso, la prioridad es comprender la estructura conceptual que conecta variables independientes, mediadoras, moderadoras y dependientes. En cambio, un modelo predictivo busca estimar qué tan bien un conjunto de constructos permite anticipar un resultado. Esta diferencia es importante porque un modelo puede explicar teóricamente una relación y, aun así, mostrar capacidad predictiva limitada; también puede predecir razonablemente un resultado sin ofrecer una explicación teórica profunda. En ciencias de la administración, lo más pertinente suele ser integrar ambas finalidades: **explicar para comprender y predecir para orientar decisiones**. Por ejemplo, en un modelo sobre innovación sostenible, no basta con afirmar que la cultura organizacional, las capacidades dinámicas y el liderazgo sostenible se relacionan con el desempeño innovador. Es necesario explicar por qué esas variables producen condiciones favorables para innovar y, además, valorar si realmente contribuyen a anticipar el resultado. **La explicación aporta profundidad teórica; la predicción aporta utilidad empírica y aplicada**. Por ello, la lógica del modelo debe declarar si su propósito principal es confirmar una teoría, desarrollar un marco conceptual, explicar varianza, anticipar resultados o combinar estas metas dentro de una arquitectura estructural coherente (Shmueli et al., 2016).

En esta transición, la aportación conceptual del investigador es decisiva, porque el modelo estructural no surge de manera automática a partir de la literatura ni de los datos. El investigador debe transformar el problema en una **red lógica de constructos**, donde cada variable ocupe una función precisa: antecedente, mecanismo, condición o consecuencia. Esta labor exige pasar de una idea amplia a un sistema conceptual ordenado. Por ejemplo, no basta con estudiar “innovación” o “inteligencia artificial”; el investigador debe precisar qué resultado desea explicar, qué

factores pueden influir en él, qué relaciones son plausibles y qué evidencia permitiría sostenerlas. En este sentido, la lógica estructural es una forma de pensamiento científico aplicado: permite organizar el fenómeno, formular hipótesis, diseñar mediciones y preparar el análisis empírico. **El modelo SEM no debe ser una colección de variables, sino una representación argumentada del fenómeno**. Esta idea resulta especialmente relevante en ciencias de la administración, donde los objetos de estudio suelen ser complejos, contextuales y multidimensionales. Una organización, un consumidor, un estudiante o una institución no actúan por una sola causa; sus comportamientos se explican mediante relaciones entre capacidades, percepciones, recursos, normas, prácticas y contextos. Por ello, el modelo estructural debe mostrar una cadena razonada de relaciones y no solamente una acumulación de constructos que parecen asociados al tema general (Mejía-Trejo, 2023).

La calidad del modelo estructural depende también de la calidad previa del modelo de medición. Por ello,. conviene recordar que los constructos solo pueden relacionarse con rigor si han sido representados por indicadores válidos y confiables. En SEM, la **fiabilidad compuesta o IFC/CR**, la **varianza media extraída o IVE/AVE**, las cargas factoriales, la validez convergente y la validez discriminante permiten valorar si los constructos tienen consistencia interna y diferenciación conceptual. De manera orientativa, una IFC o CR superior a **.70** suele considerarse aceptable, mientras que una IVE o AVE igual o superior a **.50** indica que el constructo explica una proporción suficiente de la varianza de sus indicadores. **Estos criterios no pertenecen únicamente a CB-SEM o PLS-SEM; forman parte de la evaluación de la calidad de medición de los constructos**. Sin embargo, deben articularse con la lógica estructural porque una ruta entre dos constructos solo es interpretable si ambos constructos están adecuadamente definidos y medidos. Si dos constructos no presentan validez discriminante, una relación estructural entre ellos puede ser redundante; si un constructo no presenta validez convergente, su efecto sobre otros constructos puede ser inestable o débil. **La medición sostiene la estructura, pero la estructura da sentido a la medición** (Fornell & Larcker, 1981).

En PLS-SEM, uno de los criterios centrales del modelo estructural es el **coeficiente de determinación R^2** , que indica la proporción de varianza explicada de un constructo endógeno por sus predictores. De manera orientativa, valores cercanos a **.25** pueden interpretarse como capacidad explicativa débil, valores cercanos a **.50** como moderada y valores cercanos a **.75** como sustancial, siempre considerando el campo de estudio y la complejidad del fenómeno. El R^2 permite responder una pregunta fundamental: **¿qué tanto explica el modelo el resultado central de la investigación?** Si el constructo dependiente es intención de uso responsable de IA generativa, el R^2 mostrará qué proporción de esa intención puede explicarse por autoeficacia, actitud, percepción de utilidad, alfabetización en IA o preocupación ética. Si el resultado es desempeño de innovación sostenible, el R^2 indicará qué tanto explican dicho desempeño variables como cultura de innovación, capacidades dinámicas, aprendizaje organizacional o liderazgo sostenible. Sin embargo, **un R^2 alto no garantiza por sí mismo calidad teórica**, porque un modelo puede explicar mucha varianza mediante constructos redundantes o relaciones poco justificadas. De igual

forma, un R^2 moderado puede ser valioso si el fenómeno es complejo y las variables incluidas son pertinentes. Por ello, el R^2 debe leerse junto con la coherencia conceptual, la magnitud de los efectos, la relevancia teórica de los predictores y el propósito analítico del estudio (Hair et al., 2019).

El **tamaño del efecto f^2** complementa la interpretación del R^2 porque permite conocer la contribución individual de cada predictor dentro del modelo estructural. Mientras el R^2 evalúa la explicación conjunta del constructo endógeno, el f^2 ayuda a responder qué tanto aporta cada constructo antecedente cuando se incluye o se excluye del modelo. De manera orientativa, valores de **.02** suelen interpretarse como efecto pequeño, valores de **.15** como efecto mediano y valores de **.35** como efecto grande. Esta información es relevante porque una ruta puede ser estadísticamente significativa, pero aportar poco a la explicación del resultado. **El f^2 permite distinguir entre relaciones detectables y relaciones sustantivamente importantes**. Por ejemplo, si la percepción de utilidad tiene un f^2 mediano sobre la intención de uso, pero la preocupación ética muestra un f^2 pequeño, ambas variables podrían participar en el modelo, aunque con distinto peso explicativo. Esta diferencia permite jerarquizar hallazgos y evitar conclusiones excesivas. En investigación administrativa, no basta con saber si una variable influye; es necesario valorar cuánto contribuye y qué importancia tiene dentro de la arquitectura completa. **La magnitud del efecto ayuda a decidir qué constructos son centrales, cuáles son complementarios y cuáles requieren reinterpretación teórica**. Así, el f^2 fortalece la discusión del modelo porque desplaza el análisis desde una lógica binaria de significativo/no significativo hacia una lectura más sustantiva de la contribución de cada predictor (Chin, 1998).

Una dimensión relevante en PLS-SEM, es la relevancia predictiva Q^2 , que permite valorar si el modelo posee capacidad para predecir los **constructos endógenos**. Como criterio general, un valor de **Q^2 mayor que cero** indica relevancia predictiva, mientras que valores iguales o menores a cero sugieren ausencia de capacidad predictiva para el constructo evaluado. Esta distinción es fundamental porque la explicación y la predicción no son equivalentes. Un modelo puede explicar relaciones dentro de los datos disponibles, pero no necesariamente anticipar adecuadamente nuevos casos o escenarios comparables. Por ello, cuando el estudio declara una orientación predictiva, no basta con reportar relaciones significativas; debe mostrarse que el modelo tiene capacidad para anticipar el resultado de interés. **La predicción exige valorar la utilidad empírica del modelo más allá de la coherencia teórica de sus rutas**. En ciencias de la administración, esta evaluación tiene alto valor práctico porque muchos modelos se diseñan para orientar decisiones: adopción tecnológica, permanencia estudiantil, comportamiento del consumidor, desempeño organizacional, innovación, sostenibilidad o compromiso laboral. En estos casos, la pregunta no es solo qué variables se relacionan con el resultado, sino cuáles ayudan a anticiparlo de manera útil. Por ello, Q^2 debe interpretarse como un criterio complementario que ayuda a determinar si el modelo no solo explica el fenómeno, sino que también aporta capacidad de anticipación empírica (Shmueli et al., 2016).

La lógica estructural también debe considerar los efectos directos, indirectos y totales. Un efecto directo representa la relación inmediata entre un constructo predictor y un constructo dependiente. Por ejemplo, la autoeficacia tecnológica puede influir directamente en la intención de uso de IA generativa. Un efecto indirecto ocurre cuando la relación entre dos constructos se transmite a través de un mediador. Por ejemplo, la alfabetización en IA puede influir en la intención de uso responsable mediante la actitud o la percepción de utilidad. El efecto total integra la suma de efectos directos e indirectos. **Esta distinción permite comprender la arquitectura profunda del modelo**, porque muchos fenómenos administrativos no operan mediante relaciones simples. Una variable puede no mostrar un efecto directo fuerte, pero puede ser importante porque activa mecanismos intermedios que posteriormente influyen en el resultado. Por ejemplo, la capacitación en IA podría no mejorar directamente el desempeño académico, pero sí fortalecer la autoeficacia, que a su vez favorece el uso estratégico y finalmente mejora el desempeño. En ese caso, la influencia real de la capacitación se observa mediante una cadena mediada. **Los efectos indirectos permiten explicar procesos; los efectos totales permiten valorar la importancia global de un constructo dentro de la red estructural**. Por ello, el modelo debe anticipar conceptualmente qué relaciones serán directas y cuáles operarán mediante mecanismos, evitando agregar mediaciones solo porque el software las permite (Mejía-Trejo, 2023).

La moderación introduce otra dimensión de la lógica estructural porque permite reconocer que una relación no siempre opera con la misma intensidad en todos los contextos. Una moderación se plantea cuando la relación entre dos constructos cambia según el nivel o la presencia de un tercer constructo. Por ejemplo, la relación entre actitud hacia la IA e intención de uso responsable podría ser más fuerte cuando existen protocolos institucionales claros; o la relación entre liderazgo e innovación podría fortalecerse cuando la organización ofrece autonomía al personal. **La moderación responde a la pregunta: bajo qué condiciones una relación se fortalece, se debilita o cambia de dirección**. Esta lógica es especialmente pertinente en ciencias de la administración porque los fenómenos organizacionales dependen de condiciones contextuales, institucionales, tecnológicas y culturales. Sin embargo, la moderación no debe confundirse con la mediación. Mientras la mediación explica cómo ocurre una relación, la moderación explica cuándo o bajo qué condiciones ocurre. Esta diferencia debe reflejarse en el modelo gráfico, en la formulación de hipótesis y en la interpretación de resultados. **La función conceptual de una variable determina su posición estructural: puede ser antecedente, mediadora, moderadora o consecuencia, pero no debe ocupar un papel ambiguo**. Incorporar moderadores sin justificación puede saturar el modelo; incorporarlos con fundamento puede enriquecer la explicación del fenómeno y mostrar que las relaciones estructurales no son universales ni automáticas (Hair et al., 2019).

La evaluación de la lógica estructural exige verificar que los constructos predictores cumplan funciones conceptuales diferenciadas dentro del modelo. Antes de estimar relaciones, el investigador debe preguntarse si cada antecedente, mediador o moderador aporta una explicación propia o si repite el contenido de otro

constructo con un nombre distinto. Por ejemplo, percepción de utilidad, beneficio percibido y valor percibido pueden estar relacionados, pero no deben funcionar como equivalentes conceptuales dentro de la misma arquitectura estructural. Esta revisión pertenece al plano teórico-relacional: busca asegurar que cada flecha del modelo represente una relación defendible y no una duplicación conceptual. La evaluación técnica de colinealidad mediante VIF corresponde al Capítulo 5, cuando el modelo de medición y el modelo estructural ya han sido especificados para su análisis empírico (Hair et al., 2021). Cuando el enfoque es **CB-SEM**, la evaluación del modelo incorpora una lógica distinta, centrada en el **ajuste global** entre el modelo teórico propuesto y la matriz de covarianzas observada. En este enfoque, suelen reportarse indicadores como **Chi-cuadrada χ^2**, **grados de libertad gl**, **valor p**, **χ^2/gl**, **NFI**, **NNFI o TLI**, **CFI**, **RMSEA** y **SRMR**. La Chi-cuadrada evalúa la discrepancia entre lo observado y lo estimado; los grados de libertad expresan restricciones del modelo; el valor p permite valorar la significancia de esa discrepancia; y la razón χ^2/gl se usa como criterio relativo de ajuste. Además, índices incrementales como NFI, NNFI/TLI y CFI permiten comparar el modelo con modelos de referencia, mientras que RMSEA y SRMR se orientan a errores o residuos de aproximación. De manera orientativa, valores de **CFI, NFI y NNFI/TLI cercanos o superiores a .90** suelen considerarse aceptables y valores próximos a **.95** más exigentes; **RMSEA menor a .08** suele interpretarse como aceptable y menor a **.06** como más estricto; **SRMR menor a .08** suele considerarse adecuado. **Estos índices son propios de una lógica de ajuste global en CB-SEM y no deben confundirse con los criterios centrales de PLS-SEM**, donde el énfasis se coloca en varianza explicada, predicción y relevancia de rutas (Hair et al., 2019).

La presencia de índices como **χ^2, gl, p, NFI, NNFI/TLI, CFI, RMSEA y SRMR** no significa que el modelo sea automáticamente correcto desde el punto de vista teórico. Un modelo puede presentar indicadores aceptables de ajuste global y, aun así, contener relaciones poco justificadas, constructos redundantes o hipótesis débiles. Del mismo modo, un índice de ajuste limitado puede señalar la necesidad de revisar la estructura teórica, la especificación del modelo o la calidad de la medición. **Los índices de ajuste ayudan a diagnosticar, pero no reemplazan el razonamiento conceptual**. En CB-SEM, el investigador debe evitar modificar el modelo únicamente para mejorar índices, sin justificación teórica. Las modificaciones estadísticas pueden aumentar el ajuste aparente, pero debilitar la integridad científica si no responden al problema de investigación. Por ello, cualquier ajuste debe ser defendible desde la teoría, la literatura y la lógica del fenómeno. Esta recomendación también aplica a PLS-SEM: no se deben eliminar indicadores, agregar rutas o reconfigurar relaciones únicamente para obtener valores favorables. **La estadística debe servir a la teoría, no sustituirla**. En modelos estructurales, la calidad científica depende de la articulación entre conceptualización, medición, ajuste, explicación, predicción e interpretación sustantiva (Mejía-Trejo, 2023).

La comparación entre **PLS-SEM** y **CB-SEM** debe presentarse con cuidado para evitar mezclas metodológicas. En PLS-SEM, el énfasis suele colocarse en la evaluación del modelo de medición, la explicación de varianza mediante $\boldsymbol{R^2}$, el tamaño del efecto $\boldsymbol{f^2}$, la relevancia predictiva $\boldsymbol{Q^2}$, la colinealidad **VIF** y la significancia de las

rutas estructurales. En CB-SEM, el énfasis principal se dirige al ajuste global del modelo mediante índices como **χ^2, gl, p, NFI, NNFI/TLI, CFI, RMSEA y SRMR**. Ambos enfoques pueden ser rigurosos, pero responden a finalidades distintas. **PLS-SEM suele ser pertinente cuando el interés se orienta hacia predicción, desarrollo teórico, explicación de varianza o modelos complejos; CB-SEM suele ser pertinente cuando se busca confirmar un modelo teórico con énfasis en ajuste global**. Esto no significa que uno sea superior al otro en todos los casos, sino que la elección debe responder al propósito del estudio, la naturaleza del modelo y la pregunta de investigación. Por ello, el investigador debe justificar desde el diseño si utilizará PLS-SEM, CB-SEM o si presentará una discusión comparativa. **La coherencia metodológica exige usar los indicadores adecuados para el enfoque elegido, sin trasladar criterios de manera mecánica** (Shmueli et al., 2016).

La interpretación del modelo estructural exige considerar la dirección y el signo de los coeficientes de ruta. Un coeficiente positivo indica que, al aumentar el constructo predictor, tiende a aumentar el constructo dependiente; un coeficiente negativo indica que, al aumentar el predictor, tiende a disminuir el resultado. Sin embargo, el signo debe interpretarse siempre en relación con la hipótesis, la teoría y la lógica del fenómeno. Por ejemplo, se esperaría que la autoeficacia tecnológica tenga un efecto positivo sobre la intención de uso, mientras que la ansiedad tecnológica podría tener un efecto negativo sobre la actitud o la intención. **El signo del coeficiente debe coincidir con la dirección conceptual propuesta; si no coincide, el resultado debe discutirse, no forzarse**. Los resultados inesperados pueden revelar condiciones contextuales, problemas de medición, relaciones no previstas o nuevas explicaciones teóricas. Además, la magnitud del coeficiente debe leerse junto con el tamaño del efecto, la significancia, el intervalo de confianza y la relevancia sustantiva. Una ruta pequeña puede ser importante si participa en una cadena indirecta; una ruta grande puede ser cuestionable si conecta constructos conceptualmente redundantes. **Cada coeficiente debe interpretarse dentro de la arquitectura completa del modelo, no como un número aislado** (Hair et al., 2019).

La lógica estructural debe mantener una relación estrecha con el modelo gráfico. Cada flecha representa una relación esperada; cada constructo tiene una función dentro del sistema; cada hipótesis debe poder localizarse visualmente; y cada ruta debe tener un criterio de evaluación. En este sentido, el modelo gráfico no es un adorno, sino una herramienta de trazabilidad. **La representación visual permite verificar si el sistema conceptual es coherente antes de estimarlo empíricamente**. Por ejemplo, si una hipótesis afirma que la actitud media la relación entre autoeficacia e intención, el diagrama debe mostrar la ruta desde autoeficacia hacia actitud y desde actitud hacia intención. Si se plantea una moderación, debe quedar claro qué relación se modifica y por qué. La claridad gráfica también ayuda a distinguir entre variables exógenas y endógenas, antecedentes y consecuencias, mecanismos y condiciones. Un modelo visualmente saturado puede ocultar problemas de parsimonia; un modelo demasiado simple puede omitir mecanismos relevantes. Por ello, la lógica estructural debe equilibrar claridad y suficiencia. **Un buen modelo**

gráfico permite comprender qué se explica, qué se predice, por medio de qué rutas y con qué criterios se evaluará la propuesta (Chin, 1998).

En este tema conviene insistir en que los niveles y límites son criterios orientativos, no reglas absolutas. Los valores de R^2, f^2, Q^2, VIF, CFI, NFI, NNFI/TLI, RMSEA o SRMR ayudan a diagnosticar la calidad del modelo, pero deben interpretarse en relación con el enfoque SEM utilizado, el problema de investigación, el campo disciplinar y la coherencia conceptual. **Un valor favorable no compensa un modelo teóricamente débil; un valor moderado puede ser aceptable si el fenómeno es complejo y el modelo está bien fundamentado**. Esta idea evita una lectura mecánica de SEM, donde el investigador solo busca alcanzar umbrales sin analizar el sentido de las relaciones. En ciencias de la administración, muchos fenómenos son abiertos, multifactoriales y contextuales; por tanto, los criterios técnicos deben leerse como parte de una interpretación más amplia. El objetivo no es "hacer que el modelo pase", sino construir una explicación o predicción defendible, útil y transparente. **La evaluación estructural debe integrar teoría, medición, ajuste, explicación, predicción y relevancia sustantiva**. Solo cuando estos elementos se articulan, el análisis SEM deja de ser una operación estadística y se convierte en una herramienta científica para comprender fenómenos administrativos complejos (Shmueli et al., 2016).

En síntesis, el tema permite comprender que un modelo estructural no se evalúa únicamente por la existencia de relaciones entre variables, sino por su **capacidad para explicar, predecir y representar lógicamente un fenómeno**. En **PLS-SEM**, el énfasis se coloca en la medición, la explicación de varianza, la predicción, la colinealidad, los efectos estructurales y la relevancia de los predictores. En **CB-SEM**, adquieren mayor importancia los índices de ajuste global, como **χ^2, gl, p, NFI, NNFI/TLI, CFI, RMSEA y SRMR**. A su vez, criterios como **IFC/CR e IVE/AVE** recuerdan que toda relación estructural depende de constructos correctamente medidos. **Un modelo sólido no es aquel que acumula más indicadores, sino aquel que utiliza los criterios adecuados según el enfoque metodológico elegido y los interpreta con fundamento teórico**. Por ello, los niveles y límites deben entenderse como guías de diagnóstico, no como reglas mecánicas. La calidad del modelo depende de la integración entre teoría, medición, explicación, predicción, ajuste metodológico e interpretación sustantiva. Solo cuando estos elementos se articulan de manera coherente, el análisis SEM puede ofrecer una contribución válida para las ciencias de la administración (Hair et al., 2019).

Hipótesis del modelo: contraste, significancia y apoyo empírico

Después de delimitar el fenómeno investigable, definir las variables, precisar los constructos, establecer indicadores y organizar la lógica explicativa-predictiva del modelo, el investigador debe avanzar hacia la formulación de **hipótesis estructurales**. Esta fase es decisiva porque convierte el sistema conceptual en proposiciones específicas que podrán evaluarse empíricamente. En SEM y PLS-SEM, una hipótesis

no debe redactarse como una idea general, sino como una afirmación precisa sobre la relación esperada entre constructos. Por ejemplo, no basta con afirmar que “la inteligencia artificial influye en los estudiantes”; es necesario precisar qué constructo antecedente se relaciona con qué constructo consecuente, en qué dirección y con qué fundamento conceptual. **Una hipótesis bien formulada debe ser clara, direccional, medible y coherente con el modelo gráfico**, porque cada hipótesis representa una ruta estructural que posteriormente será evaluada mediante coeficientes, valores t, valores p, intervalos de confianza y criterios de apoyo empírico. En este sentido, el tema 3.4 no repite la evaluación global del modelo estructural, sino que se concentra en el **contraste formal de las relaciones propuestas** (Hair et al., 2019).

La hipótesis cumple una función de puente entre la teoría y la evidencia empírica. Por un lado, surge de la revisión conceptual, del problema de investigación y de la lógica del modelo; por otro, orienta el análisis estadístico al indicar qué relación específica debe evaluarse. En un modelo estructural, cada flecha debe tener una hipótesis o una justificación explícita. Si una ruta no puede formularse como hipótesis, probablemente carece de suficiente claridad conceptual. Por ejemplo, si el modelo propone que la autoeficacia tecnológica influye en la actitud hacia el uso académico de inteligencia artificial generativa, esa relación debe expresarse en una hipótesis como: **H1: La autoeficacia tecnológica influye positivamente en la actitud hacia el uso académico de inteligencia artificial generativa**. Esta redacción permite identificar el antecedente, el consecuente y la dirección esperada. **La hipótesis debe poder localizarse visualmente en el modelo**, de modo que exista correspondencia entre texto, diagrama, instrumento y análisis posterior (Chin, 1998).

La formulación de hipótesis debe evitar dos errores frecuentes. El primero consiste en redactar hipótesis demasiado amplias, imposibles de contrastar con precisión. El segundo consiste en formular hipótesis solo porque existen datos disponibles, sin que haya una lógica conceptual que las respalde. Una hipótesis estructural no debe surgir del azar ni de la conveniencia estadística; debe derivarse de una relación teóricamente plausible entre constructos. **El investigador no formula hipótesis para llenar el modelo, sino para someter a evaluación relaciones relevantes para explicar o predecir el fenómeno**. Cuando el estudio tiene orientación predictiva, las hipótesis deben vincularse con constructos capaces de anticipar el resultado central; cuando tiene orientación explicativa, deben mostrar mecanismos, antecedentes o condiciones que permitan comprender el fenómeno. De esta forma, las hipótesis se convierten en el punto donde la arquitectura conceptual adquiere forma evaluable. Si las hipótesis no están alineadas con la lógica del modelo, los resultados estadísticos posteriores serán difíciles de interpretar (Shmueli et al., 2016).

El primer tipo de hipótesis corresponde a los efectos directos. Estas hipótesis plantean que un constructo antecedente influye directamente sobre un constructo consecuente. Su estructura básica puede expresarse como: **X influye positiva o negativamente en Y**. Por ejemplo, “la percepción de utilidad influye positivamente en la actitud hacia el uso de inteligencia artificial generativa” o “la ansiedad tecnológica

influye negativamente en la intención de uso académico". Sin embargo, una hipótesis de efecto directo no debe limitarse a unir dos variables; debe estar acompañada por una explicación conceptual. El investigador debe justificar por qué se espera esa relación, qué proceso la sostiene y por qué tiene sentido dentro del fenómeno. **El efecto directo representa una relación estructural inmediata, pero su valor científico depende de la teoría que lo respalda**. En PLS-SEM, estas hipótesis se evalúan mediante el coeficiente de ruta, el signo esperado, el valor t, el valor p y el intervalo de confianza (Hair et al., 2019).

El segundo tipo corresponde a las hipótesis de mediación. Una mediación se plantea cuando la relación entre un constructo antecedente y un constructo consecuente ocurre a través de un tercer constructo que funciona como mecanismo explicativo. Por ejemplo, la alfabetización en inteligencia artificial puede influir en la intención de uso responsable mediante la autoeficacia tecnológica o la actitud hacia la IA. En este caso, el mediador ayuda a explicar cómo se transmite el efecto. **La mediación no solo pregunta si X influye en Y, sino cómo o por medio de qué proceso ocurre esa influencia**. Una hipótesis de mediación podría redactarse así: **H2: La actitud hacia el uso académico de IA generativa media la relación entre autoeficacia tecnológica e intención de uso responsable**. Esta formulación permite distinguir entre una relación directa y una relación procesual. En modelos SEM, las mediaciones son especialmente útiles porque los fenómenos administrativos, educativos y organizacionales rara vez operan mediante relaciones simples o lineales (Chin, 1998).

El tercer tipo corresponde a las hipótesis de moderación. Una moderación se formula cuando se espera que la relación entre dos constructos cambie según el nivel, presencia o intensidad de un tercer constructo. A diferencia de la mediación, la moderación no explica el mecanismo de transmisión, sino la condición bajo la cual una relación se fortalece, debilita o cambia de dirección. Por ejemplo, la relación entre actitud e intención de uso responsable de IA generativa podría ser más fuerte cuando existen protocolos institucionales claros. **La moderación responde a la pregunta: bajo qué condiciones una relación se modifica**. Una hipótesis moderadora podría redactarse así: **H3: Los protocolos institucionales moderan positivamente la relación entre actitud hacia la IA e intención de uso responsable**. Este tipo de hipótesis debe incorporarse con cuidado, porque aumenta la complejidad del modelo y exige una justificación conceptual robusta. No debe añadirse una moderación solo para sofisticar el análisis, sino porque el contexto del fenómeno lo requiere (Shmueli et al., 2016).

También pueden formularse hipótesis de efectos indirectos y efectos totales. Un efecto indirecto ocurre cuando un constructo influye en otro por medio de uno o más mediadores. Un efecto total integra el efecto directo y los efectos indirectos de un constructo sobre otro. Por ejemplo, la alfabetización en IA podría influir en la intención de uso responsable tanto de manera directa como indirecta mediante autoeficacia, percepción de utilidad y actitud. **El efecto total permite valorar la influencia global de un constructo dentro de la red estructural**. Esta distinción es relevante porque

una variable puede no mostrar un efecto directo significativo, pero sí tener un efecto indirecto importante. En ese caso, el investigador no debería concluir que la variable carece de relevancia; debería analizar si su efecto opera mediante mecanismos intermedios. En SEM y PLS-SEM, esta lectura evita interpretaciones simplistas y permite comprender mejor la arquitectura relacional del modelo (Hair et al., 2019).

La formulación de hipótesis exige cuidar la direccionalidad. En un modelo estructural, la dirección de la relación no debe decidirse únicamente por correlaciones estadísticas, sino por teoría, temporalidad conceptual y lógica del fenómeno. Por ejemplo, si se plantea que la actitud influye en la intención de uso, el investigador debe justificar por qué la disposición evaluativa antecede a la intención conductual. Si se plantea que la autoeficacia influye en la actitud, debe argumentarse por qué la percepción de capacidad puede favorecer una valoración positiva del uso tecnológico. **La dirección de una hipótesis es una decisión conceptual antes que estadística**. Esto resulta especialmente importante en estudios transversales, donde los datos se recolectan en un solo momento y no permiten afirmar causalidad definitiva. Por ello, el lenguaje debe ser prudente: es mejor hablar de influencia esperada, relación estructural o efecto estimado, en lugar de afirmar causalidad absoluta cuando el diseño no la sostiene (Chin, 1998).

U**na vez formuladas las hipótesis, el investigador debe contrastarlas empíricamente.** En PLS-SEM, este contraste suele realizarse mediante ***bootstrapping***, procedimiento que permite estimar errores estándar, valores t, valores p e intervalos de confianza a partir de múltiples remuestreos. **El *bootstrapping* permite valorar si un coeficiente de ruta es estadísticamente distinto de cero**, es decir, si existe evidencia empírica suficiente para apoyar la relación propuesta. En términos prácticos, una hipótesis suele recibir apoyo cuando el coeficiente presenta el signo esperado, alcanza significancia estadística y muestra coherencia con el argumento teórico. No obstante, el contraste no debe interpretarse de manera mecánica. Un valor significativo puede carecer de relevancia práctica si el efecto es muy pequeño; del mismo modo, una relación no significativa puede ofrecer información valiosa sobre los límites del modelo, el contexto o la teoría utilizada. El contraste de hipótesis debe integrar evidencia estadística y juicio conceptual (Hair et al., 2019).

Los **niveles de significancia estadística** permiten valorar la probabilidad de obtener un resultado igual o más extremo si la hipótesis nula fuera verdadera. En investigación administrativa y social suelen emplearse los niveles **p < .05**, **p < .01** y **p < .001**. El nivel **p < .05** representa el criterio convencional mínimo para considerar una relación estadísticamente significativa; **p < .01** indica evidencia más fuerte; y **p < .001** representa evidencia estadística muy fuerte. En algunos estudios exploratorios puede reportarse **p < .10** como significancia marginal, aunque debe interpretarse con prudencia y justificarse claramente. **La significancia estadística indica apoyo empírico contra la hipótesis nula, pero no demuestra por sí sola relevancia teórica, importancia práctica ni causalidad absoluta**. Por ello, el valor p debe leerse como un indicador de evidencia estadística, no como una prueba única y suficiente de calidad científica (Shmueli et al., 2016).

Los **valores t** complementan la interpretación de los valores p. En pruebas bilaterales, un valor t aproximado de **1.96** suele asociarse con **p < .05**; un valor cercano a **2.58** se relaciona con **p < .01**; y valores superiores a **3.29** suelen asociarse con **p < .001**. En pruebas unilaterales, los puntos críticos pueden ser menores, por ejemplo, alrededor de **1.645** para **p < .05**, siempre que la hipótesis haya sido formulada con dirección específica antes del análisis. **El tipo de prueba debe definirse antes de observar los resultados**, porque elegir unilateral o bilateral después de revisar los datos puede generar sesgos interpretativos. En investigaciones académicas, la prueba bilateral suele ser más conservadora cuando se desea evaluar si existe una relación distinta de cero en cualquier dirección. En cambio, la prueba unilateral puede justificarse cuando la teoría sostiene claramente una dirección esperada (Hair et al., 2019).

Los **intervalos de confianza** ofrecen una lectura adicional sobre la estabilidad del efecto estimado. Un intervalo de confianza muestra el rango probable en el que se ubica el coeficiente poblacional. En el contraste de hipótesis estructurales, si el intervalo de confianza de un coeficiente **no incluye el cero**, se considera que la relación recibe apoyo estadístico. Por ejemplo, si una ruta presenta un intervalo de confianza de .12 a .35, puede interpretarse como un efecto positivo distinto de cero. En cambio, si el intervalo va de -.04 a .28, incluye cero y, por tanto, la hipótesis no recibe apoyo con ese nivel de confianza. **El intervalo de confianza ayuda a interpretar no solo la significancia, sino también la precisión del efecto**. Esta información es valiosa porque evita una lectura exclusivamente dicotómica basada en significativo/no significativo y permite observar la estabilidad del coeficiente estimado (Chin, 1998).

La decisión sobre una hipótesis debe considerar al menos cuatro elementos: signo, magnitud, significancia y coherencia teórica. El signo indica si la relación es positiva o negativa. La magnitud muestra la fuerza del coeficiente. La significancia indica si la relación es estadísticamente distinta de cero. La coherencia teórica permite valorar si el resultado tiene sentido dentro del marco conceptual. Por ejemplo, si se esperaba que la autoeficacia tecnológica influyera positivamente en la actitud y el resultado muestra un coeficiente positivo, significativo y de magnitud relevante, la hipótesis recibe apoyo sólido. En cambio, si el coeficiente es significativo pero pequeño, el apoyo debe discutirse con cautela. **Una hipótesis no se interpreta solo por el valor p, sino por la integración entre evidencia estadística y sentido sustantivo**. Esta lectura evita sobrevalorar relaciones débiles o estadísticamente significativas solo por el tamaño de muestra (Shmueli et al., 2016).

Es preferible afirmar que una hipótesis recibe apoyo empírico o no recibe apoyo empírico, en lugar de decir que fue "comprobada" o "rechazada" de manera absoluta. Esta redacción es metodológicamente más prudente porque reconoce que los resultados dependen de una muestra, un contexto, un instrumento y un modelo específico. **Una hipótesis no apoyada no necesariamente es falsa; puede indicar que la relación no se observó bajo las condiciones del estudio**. Por ejemplo, una relación entre ansiedad tecnológica e intención de uso podría no ser

significativa en estudiantes con alta familiaridad digital, pero sí en poblaciones con menor experiencia tecnológica. De igual forma, una relación no apoyada puede revelar la existencia de mediadores o moderadores no considerados. Por ello, los resultados deben discutirse con apertura analítica y no como simples éxitos o fracasos del modelo (Hair et al., 2019).

La interpretación de hipótesis no apoyadas puede aportar valor científico. Cuando una relación esperada no resulta significativa, el investigador debe analizar posibles explicaciones: medición insuficiente, falta de variabilidad en la muestra, diferencias contextuales, efectos indirectos no previstos, presencia de moderadores o límites de la teoría en ese campo específico. **Un resultado no significativo puede revelar una frontera del conocimiento**, especialmente cuando contradice supuestos previos o muestra que una relación no opera igual en todos los contextos. Por ejemplo, si la percepción de utilidad no influye directamente en la intención de uso, pero sí lo hace mediante la actitud, el modelo podría requerir una lectura mediada. Si la preocupación ética no reduce la intención de uso, quizá los participantes no perciben la ética como barrera, sino como criterio para usar mejor la tecnología. Estos hallazgos pueden enriquecer la discusión y abrir nuevas líneas de investigación (Chin, 1998).

La significancia estadística debe distinguirse de la relevancia práctica. Una relación puede ser estadísticamente significativa debido a un tamaño de muestra grande, pero tener un efecto tan pequeño que su utilidad práctica sea limitada. Por el contrario, una relación de magnitud moderada puede ser relevante para la toma de decisiones, aunque requiera confirmación en estudios posteriores. **El valor p no mide la importancia del efecto; solo ayuda a valorar la evidencia estadística contra la hipótesis nula**. En ciencias de la administración, esta distinción es central porque los modelos suelen derivar implicaciones para organizaciones, instituciones educativas, innovación, gestión del talento, comportamiento del consumidor o adopción tecnológica. Por ello, una hipótesis debe interpretarse también en función de su contribución al fenómeno, su tamaño de efecto, su utilidad conceptual y su posible aplicación práctica (Shmueli et al., 2016).

La redacción de las hipótesis debe mantener uniformidad formal. Una forma recomendable es numerarlas de manera secuencial: **H1, H2, H3, H4**, etc. Cuando existan relaciones derivadas, mediaciones o moderaciones, pueden utilizarse subhipótesis como **H3a, H3b o H3c**. Cada hipótesis debe incluir el constructo antecedente, el constructo consecuente y la dirección esperada de la relación. Por ejemplo: H1: La alfabetización en IA influye positivamente en la autoeficacia tecnológica; H2: La autoeficacia tecnológica influye positivamente en la actitud hacia el uso académico de IA generativa; H3: La actitud hacia la IA influye positivamente en la intención de uso responsable. La redacción uniforme facilita la correspondencia entre hipótesis, modelo gráfico y tabla de resultados. Además, reduce ambigüedades y permite que el lector identifique con rapidez qué relación será evaluada (Hair et al., 2019).

La correspondencia entre hipótesis y modelo gráfico es indispensable. Si una hipótesis aparece en el texto, debe existir una ruta correspondiente en el diagrama. Si

una flecha aparece en el diagrama, debe contar con una hipótesis o una justificación explícita. **Modelo gráfico, hipótesis, instrumento y análisis deben formar un sistema coherente**. Por ejemplo, no sería adecuado formular una hipótesis sobre el efecto de la preocupación ética en la actitud si esa ruta no aparece en el modelo gráfico. Tampoco sería correcto dibujar una flecha entre cultura de innovación y desempeño sostenible sin formular la hipótesis correspondiente. Esta trazabilidad facilita la evaluación por pares y fortalece la transparencia metodológica. En investigación estructural, la hipótesis no es un elemento aislado; forma parte de una cadena que inicia en el problema, continúa en los constructos, se expresa en el modelo gráfico y se contrasta mediante análisis empírico (Chin, 1998).

Una estrategia útil para fortalecer la trazabilidad consiste en elaborar una tabla de hipótesis. Esta tabla puede incluir el número de hipótesis, la relación propuesta, el tipo de efecto, el signo esperado, el criterio de contraste y la decisión posterior. **La tabla de hipótesis funciona como un mapa metodológico entre el sistema conceptual y la evaluación empírica**. Además, facilita la presentación de resultados, porque el investigador puede reportar para cada hipótesis el coeficiente de ruta, valor t, valor p, intervalo de confianza y conclusión de apoyo o no apoyo. En modelos con varias relaciones, esta tabla evita confusiones y permite ordenar la discusión. También ayuda a verificar que no existan hipótesis sin ruta, rutas sin hipótesis o relaciones mal clasificadas como directas, mediadas o moderadas. En términos editoriales, mejora la claridad y la trazabilidad del capítulo (Shmueli et al., 2016).

El contraste de hipótesis debe realizarse después de verificar que el modelo de medición cumple criterios mínimos de calidad. Si los constructos no presentan confiabilidad, validez convergente o validez discriminante suficiente, las hipótesis estructurales pueden interpretarse de manera errónea. **No se deben discutir relaciones estructurales sobre constructos mal medidos**. Por ejemplo, si actitud y percepción de utilidad no se diferencian adecuadamente, la ruta entre ambas podría reflejar traslape conceptual más que una relación estructural real. Si un constructo tiene indicadores débiles, el coeficiente de ruta puede subestimarse o distorsionarse. Por ello, la secuencia metodológica debe ser clara: primero se evalúa la medición; después se examina el modelo estructural; finalmente se contrastan las hipótesis. Esta progresión permite que las conclusiones se sostengan sobre mediciones aceptables y relaciones interpretables (Hair et al., 2019).

En la presentación de resultados, cada hipótesis debería reportarse con información suficiente para ser verificable. Una forma recomendable es incluir el coeficiente de ruta, el valor t, el valor p, el intervalo de confianza y la decisión de apoyo empírico. Por ejemplo: **H1 recibió apoyo empírico: $\beta = .32$, $t = 4.21$, $p < .001$, IC 95% [.18, .45]**. Esta presentación permite observar el signo, la magnitud y la precisión del efecto. **El reporte de hipótesis debe ser transparente, completo y verificable**, porque no basta con afirmar que una relación fue significativa; deben mostrarse los criterios que sustentan esa afirmación. En libros de investigación, tesis y artículos científicos, esta práctica fortalece la credibilidad del análisis y facilita la revisión

académica. Además, permite comparar resultados entre estudios y valorar la consistencia de los hallazgos en diferentes contextos (Chin, 1998).

El lenguaje utilizado al interpretar hipótesis debe ser prudente. En lugar de decir "se comprobó la hipótesis", resulta más apropiado escribir "la hipótesis recibió apoyo empírico" o "los resultados son consistentes con la relación propuesta". De igual forma, en vez de afirmar "la hipótesis fue rechazada", es preferible señalar "la hipótesis no recibió apoyo empírico en esta muestra". **La prudencia terminológica evita afirmaciones absolutas y reconoce el carácter contextual de la evidencia científica**. Esto es especialmente importante en estudios transversales y no experimentales, donde las relaciones estructurales son estimadas a partir de un modelo teórico, pero no equivalen necesariamente a causalidad definitiva. Un lenguaje cuidadoso fortalece la calidad académica del capítulo, porque muestra que el investigador comprende los alcances y límites del método utilizado (Shmueli et al., 2016).

Representación gráfica, trazabilidad y coherencia interna del modelo estructural

La representación gráfica del modelo estructural constituye el momento en que el sistema conceptual adquiere una forma visual ordenada. Después de delimitar el fenómeno, definir constructos, establecer indicadores, precisar la lógica explicativa-predictiva y formular hipótesis, el investigador debe representar esas relaciones mediante un diagrama que permita observar la arquitectura completa del modelo. **El diagrama no debe entenderse como un recurso decorativo, sino como una síntesis metodológica de la investigación**, porque muestra qué constructos actúan como antecedentes, cuáles funcionan como variables dependientes, qué relaciones son directas, cuáles son mediadas, dónde aparecen posibles moderaciones y cómo se articula el fenómeno estudiado. En SEM y PLS-SEM, esta representación visual ayuda a verificar si existe correspondencia entre el problema de investigación, los objetivos, las hipótesis y el análisis posterior. Por ello, cada flecha debe expresar una relación teóricamente fundamentada y cada constructo debe ocupar una función clara dentro del modelo. Si el diagrama contiene rutas que no fueron justificadas o hipótesis que no aparecen visualmente, la investigación pierde coherencia interna. **Un modelo gráfico sólido debe permitir que el lector comprenda, de manera inmediata, cuál es la lógica estructural que será evaluada empíricamente** (Hair et al., 2019).

La construcción del diagrama debe partir de la identificación de los constructos exógenos y endógenos. Los **constructos exógenos** funcionan como antecedentes dentro del modelo, porque explican o predicen otros constructos sin recibir flechas de variables previas en la estructura propuesta. Los **constructos endógenos**, en cambio, reciben una o más rutas estructurales y representan resultados, consecuencias o mecanismos intermedios. Por ejemplo, en un modelo sobre adopción de inteligencia artificial generativa, la alfabetización en IA podría

funcionar como constructo exógeno, mientras que la autoeficacia, la actitud y la intención de uso responsable podrían funcionar como constructos endógenos. **Distinguir entre constructos exógenos y endógenos permite ordenar la lógica relacional del modelo**, porque ayuda a identificar qué variables explican, cuáles median y cuáles representan resultados. Esta distinción no implica causalidad absoluta, especialmente en estudios transversales, pero sí permite expresar la dirección teóricamente esperada de las relaciones estructurales (Chin, 1998).

La representación gráfica también debe responder a la finalidad explicativa o predictiva del estudio. Si el modelo busca explicar un fenómeno, el diagrama debe mostrar con claridad los antecedentes, mecanismos y consecuencias que permiten comprender por qué ocurre dicho resultado. Si el modelo busca predecir, debe organizar los constructos que permiten anticipar con mayor precisión la variable dependiente. En muchos estudios de administración, ambas finalidades se combinan: el investigador desea explicar conceptualmente un fenómeno y, al mismo tiempo, estimar su comportamiento. **El diagrama debe hacer visible qué se intenta explicar y qué se intenta predecir**. Por ejemplo, si la intención de uso responsable de IA generativa es el resultado central, las rutas deben mostrar qué constructos permiten comprender o anticipar esa intención. La claridad del modelo gráfico facilita posteriormente la interpretación de la varianza explicada, los efectos directos, los efectos indirectos y la relevancia predictiva. Un diagrama confuso dificulta distinguir si el modelo tiene una orientación teórica, predictiva o mixta (Shmueli et al., 2016).

La variable dependiente o constructo endógeno principal debe ocupar un lugar visible dentro del diagrama. Esta variable representa el resultado que el estudio busca explicar o predecir. Puede tratarse de intención de uso, desempeño de innovación sostenible, aprendizaje organizacional, compromiso laboral, adopción tecnológica, satisfacción del cliente o resiliencia empresarial. **La variable dependiente funciona como eje ordenador del modelo**, porque permite decidir qué antecedentes son pertinentes, qué mediadores tienen sentido y qué relaciones deben formularse como hipótesis. Un error frecuente consiste en construir modelos con múltiples variables sin un resultado central claramente definido. Esto debilita la investigación porque impide reconocer cuál es el fenómeno que se pretende explicar. En cambio, cuando el constructo endógeno principal está bien delimitado, el modelo adquiere dirección, jerarquía y propósito analítico. En PLS-SEM, además, los constructos endógenos serán aquellos en los que posteriormente podrá interpretarse la capacidad explicativa mediante R^2 (Hair et al., 2019).

La trazabilidad del modelo implica que cada elemento gráfico pueda rastrearse hacia una decisión conceptual previa. Esto significa que cada constructo debe derivarse del problema de investigación; cada relación debe corresponder a una hipótesis; cada hipótesis debe estar sustentada en literatura; y cada indicador debe vincularse con un constructo definido. **La trazabilidad evita que el modelo se convierta en una combinación arbitraria de variables**, porque obliga al investigador a demostrar continuidad entre teoría, medición y análisis estructural. En términos prácticos, para cada flecha del modelo el investigador debería responder cuatro

preguntas: qué constructos conecta, qué hipótesis representa, qué argumento teórico la justifica y cómo será evaluada empíricamente. Si una flecha no puede responder estas preguntas, probablemente debe eliminarse, reformularse o fundamentarse mejor. Esta revisión fortalece la coherencia interna y permite anticipar observaciones metodológicas de evaluadores, lectores o pares académicos (Chin, 1998).

La trazabilidad también debe extenderse hacia la capacidad predictiva del modelo. Un diagrama no solo muestra relaciones teóricas, sino que anticipa qué constructos tendrán que demostrar utilidad empírica para explicar o predecir el resultado de interés. Por ejemplo, si la actitud, la autoeficacia y la percepción de utilidad se proponen como predictores de intención de uso, el modelo debe permitir evaluar si estos constructos realmente aportan al comportamiento esperado. **Una ruta gráfica representa una expectativa conceptual, pero también una responsabilidad empírica**. Esto significa que la flecha no solo debe justificarse en la teoría, sino que después deberá analizarse mediante coeficientes, efectos, significancia y criterios predictivos. En este sentido, la representación gráfica prepara el tránsito hacia la evaluación estructural, porque permite anticipar cuáles relaciones serán centrales, cuáles serán complementarias y cuáles deberán interpretarse como mecanismos indirectos o condiciones contextuales (Shmueli et al., 2016).

La representación gráfica debe diferenciar con precisión entre modelo de medición y modelo estructural. El modelo de medición muestra la relación entre constructos e indicadores; el modelo estructural muestra las relaciones entre constructos. Esta distinción es crucial porque el investigador debe evitar mezclar niveles de análisis. Los indicadores no deben confundirse con las variables latentes, del mismo modo que las hipótesis estructurales no deben confundirse con los ítems del cuestionario. Por ejemplo, si el constructo es autoeficacia tecnológica, los indicadores pueden medir seguridad, habilidad percibida o capacidad de resolver problemas tecnológicos; pero la ruta estructural no conecta cada ítem con la intención de uso, sino el constructo latente de autoeficacia con otro constructo latente. **El modelo de medición responde cómo se mide; el modelo estructural responde cómo se relaciona**. Esta separación es indispensable para interpretar correctamente el análisis SEM o PLS-SEM (Hair et al., 2019).

El diagrama estructural debe mostrar con precisión si las relaciones propuestas son directas, mediadas o moderadas. Una relación directa se representa mediante una flecha entre un constructo predictor y un constructo dependiente. Una relación mediada requiere incorporar un constructo intermedio que explique el mecanismo mediante el cual se transmite el efecto. Una relación moderada implica representar una condición que modifica la fuerza o dirección de una relación. **La claridad gráfica de estos efectos es indispensable para evitar confusiones analíticas**, porque cada tipo de relación exige una interpretación distinta. Por ejemplo, si la actitud media la relación entre autoeficacia e intención de uso, el modelo debe mostrar que la autoeficacia influye en la actitud y que la actitud influye en la intención. Si los protocolos institucionales moderan la relación entre actitud e intención, el modelo

debe representar esa interacción como una condición que altera la relación específica (Chin, 1998).

La claridad del modelo gráfico también ayuda a distinguir entre explicación y predicción. La mediación suele fortalecer la explicación porque muestra cómo se produce una relación, mientras que la predicción se concentra en estimar qué tan bien los constructos anticipan el resultado final. **Un modelo puede ser visualmente coherente, pero no necesariamente predictivo si sus constructos no permiten anticipar el resultado con suficiente precisión**. Por ello, cuando se representa un modelo orientado a la predicción, conviene destacar con claridad el constructo objetivo y los predictores principales. Si el modelo contiene rutas mediadas, debe quedar claro si dichas rutas buscan explicar procesos internos o mejorar la capacidad predictiva del sistema. Esta distinción evita que el diagrama se lea únicamente como una cadena de flechas, cuando en realidad representa una lógica de explicación, predicción o ambas dimensiones integradas (Shmueli et al., 2016).

La coherencia interna del modelo requiere que la dirección de las flechas responda a una lógica conceptual, no únicamente a una correlación estadística. Dos constructos pueden estar asociados, pero eso no define automáticamente cuál debe ser antecedente y cuál consecuencia. Por ejemplo, la actitud puede relacionarse con la intención de uso, pero el investigador debe justificar por qué la actitud antecede a la intención y no al revés. De igual manera, la cultura organizacional puede relacionarse con la innovación, pero se requiere explicar por qué la cultura actúa como condición antecedente del comportamiento innovador. **La dirección de las rutas es una decisión teórica antes que estadística**. Por ello, el diagrama debe construirse con base en temporalidad conceptual, argumentos de la literatura y coherencia con el problema de investigación. El software estima el modelo propuesto, pero no justifica por sí mismo la dirección conceptual de las flechas (Hair et al., 2019).

La representación gráfica debe cuidar la parsimonia. Un modelo parsimonioso no es un modelo pobre, sino un modelo que incluye únicamente los constructos y relaciones necesarios para explicar o predecir el fenómeno. **Agregar demasiadas flechas puede generar una apariencia de sofisticación, pero también puede debilitar la claridad conceptual**. Cada ruta adicional exige una hipótesis, una justificación teórica y una interpretación posterior. Si el modelo contiene relaciones redundantes, innecesarias o débilmente fundamentadas, el análisis puede volverse confuso y perder fuerza argumentativa. Por ello, antes de cerrar el diagrama, el investigador debe preguntarse si cada constructo es indispensable, si cada flecha cumple una función, si cada mediación aporta profundidad explicativa y si cada moderación responde a una condición realmente relevante. La parsimonia permite que el modelo sea comprensible, evaluable y defendible (Chin, 1998).

La parsimonia también es relevante para la predicción. Un modelo predictivo no mejora necesariamente por incorporar más constructos, porque el exceso de variables puede introducir redundancia, colinealidad o ruido interpretativo. **La capacidad predictiva depende de la pertinencia de los predictores, no solo de su cantidad**. En este sentido, el modelo gráfico debe permitir observar si los antecedentes

propuestos realmente tienen una función clara frente al constructo objetivo. Cuando el diagrama incluye muchos predictores hacia una misma variable dependiente, el investigador debe justificar por qué cada uno aporta información diferente. Si dos constructos parecen medir dimensiones demasiado cercanas, puede ser necesario revisar su diferenciación conceptual antes de estimar el modelo. Un diagrama predictivo claro debe mostrar predictores relevantes, no una acumulación indiscriminada de variables (Shmueli et al., 2016).

La trazabilidad entre hipótesis y diagrama puede fortalecerse mediante una tabla de correspondencia. Esta tabla puede incluir el número de hipótesis, la relación propuesta, el tipo de efecto, el signo esperado y la ruta representada en el modelo. **La tabla de correspondencia funciona como un mecanismo de control metodológico**, porque permite verificar que ninguna hipótesis quede fuera del diagrama y que ninguna flecha carezca de hipótesis. Por ejemplo, si H1 plantea que la autoeficacia tecnológica influye positivamente en la actitud, el diagrama debe mostrar una flecha de autoeficacia hacia actitud. Si H2 establece que la actitud influye positivamente en la intención de uso, debe existir una flecha correspondiente. Si H3 plantea una mediación, la tabla debe mostrar las rutas que integran ese efecto indirecto. Esta práctica mejora la transparencia del modelo y facilita la posterior presentación de resultados (Hair et al., 2019).

La coherencia interna del modelo también depende de la correcta identificación de constructos exógenos y endógenos. Los constructos exógenos son aquellos que funcionan como antecedentes y no reciben flechas de otros constructos dentro del modelo. Los constructos endógenos son aquellos que reciben una o más flechas y, por tanto, son explicados por otros constructos. **Distinguir entre constructos exógenos y endógenos permite comprender la jerarquía estructural del modelo**. Por ejemplo, en un modelo sobre uso responsable de IA, la alfabetización en IA podría funcionar como constructo exógeno; la autoeficacia y la actitud podrían funcionar como constructos endógenos intermedios; y la intención de uso responsable podría ser el constructo endógeno final. Esta organización ayuda a interpretar la cadena relacional propuesta. También permite distinguir entre variables que explican, variables que median y variables que representan resultados (Chin, 1998).

La representación gráfica debe anticipar la manera en que se evaluará el modelo. Una vez estimado, los constructos endógenos podrán mostrar su capacidad explicativa mediante R^2 ; los predictores podrán evaluarse mediante su tamaño de efecto; las rutas podrán contrastarse mediante coeficientes, significancia e intervalos de confianza; y las relaciones mediadas podrán analizarse mediante efectos indirectos. **El diagrama no prueba las relaciones, pero prepara la estructura que será sometida a evaluación empírica**. Esta idea es importante porque evita presentar el modelo conceptual como si ya fuera evidencia confirmada. El diagrama representa una propuesta teórica organizada; la validación requiere análisis posterior. Por ello, la presentación gráfica debe acompañarse de una narrativa que explique cómo cada parte del modelo será evaluada y qué criterios permitirán valorar su comportamiento empírico (Shmueli et al., 2016).

La representación gráfica debe ser congruente con el tipo de constructos incluidos. Si el modelo incorpora constructos reflectivos, los indicadores se representan como manifestaciones del constructo; si incorpora constructos formativos, los indicadores se representan como componentes que forman el constructo. **La forma de representar los indicadores debe ser coherente con la naturaleza conceptual de la medición**. En constructos reflectivos, se asume que el constructo causa las respuestas observadas en los indicadores; en constructos formativos, se asume que los indicadores forman el significado del constructo. Esta diferencia no es meramente gráfica, porque tiene consecuencias para la evaluación de confiabilidad, validez y colinealidad. Si el investigador representa equivocadamente un constructo formativo como reflectivo, puede aplicar criterios inadecuados y llegar a conclusiones metodológicamente débiles (Hair et al., 2019).

El modelo estructural debe mantener correspondencia con el objetivo general de la investigación. Si el objetivo declara que el estudio busca explicar los factores que influyen en un resultado, el diagrama debe mostrar relaciones explicativas coherentes con ese resultado. Si el objetivo declara que se busca predecir un comportamiento, el modelo debe incluir predictores relevantes y criterios de evaluación predictiva. **La coherencia entre objetivo y modelo gráfico es una condición básica de rigor investigativo**. Un objetivo explicativo no debería acompañarse de un modelo que solo agrupa variables sin mecanismos; un objetivo predictivo no debería acompañarse de un modelo que no identifica claramente el constructo a predecir. Por ello, al revisar el diagrama, el investigador debe preguntarse si el modelo responde directamente al objetivo planteado. Si la respuesta no es clara, probablemente el objetivo, las hipótesis o la estructura del modelo requieren ajustes (Shmueli et al., 2016).

La representación gráfica también ayuda a identificar vacíos, excesos o inconsistencias antes de la recolección de datos. Al observar el modelo, el investigador puede detectar si hay constructos sin función clara, rutas duplicadas, mediaciones innecesarias, moderaciones débiles o hipótesis desconectadas del problema central. **El diagrama permite revisar visualmente la economía lógica del modelo**. Esta revisión previa es importante porque resulta más sencillo corregir un modelo en la fase conceptual que después de haber aplicado el cuestionario y estimado los resultados. Por ejemplo, si dos constructos parecen cumplir la misma función, conviene revisar si deben fusionarse o diferenciarse mejor. Si una variable aparece aislada, debe evaluarse si realmente pertenece al modelo. Si una ruta no puede justificarse, debe eliminarse o replantearse (Chin, 1998).

La trazabilidad también debe extenderse hacia el instrumento de medición. Cada constructo del diagrama debe corresponder a una sección del cuestionario o a un conjunto de indicadores claramente identificables. **No debe existir un constructo en el modelo que no tenga indicadores medibles**, ni indicadores en el instrumento que no correspondan a ningún constructo del modelo. Esta correspondencia es esencial para asegurar que la recolección de datos responda a la arquitectura conceptual. Por ejemplo, si el modelo incluye autoeficacia, percepción de utilidad, actitud e intención, el cuestionario debe contener ítems para cada constructo y estos

ítems deben reflejar su definición conceptual. Si el instrumento incluye preguntas sobre ansiedad tecnológica, pero el modelo no contempla ese constructo, el investigador debe decidir si lo incorpora formalmente o si elimina esas preguntas. La coherencia entre modelo e instrumento evita datos sobrantes, omisiones críticas y problemas de interpretación posterior (Hair et al., 2019).

La representación gráfica también debe evitar la falsa impresión de causalidad absoluta cuando el diseño metodológico no lo permite. En muchos estudios SEM y PLS-SEM, especialmente aquellos basados en encuestas transversales, las flechas representan relaciones estructurales teóricamente fundamentadas, pero no necesariamente causalidad experimental comprobada. **El diagrama expresa la lógica relacional propuesta por el investigador, no una prueba definitiva de causalidad por sí mismo**. Por ello, la redacción debe ser prudente: se puede hablar de influencia esperada, relación estructural, efecto estimado o asociación direccional teóricamente justificada. Esta precisión es importante para evitar sobreinterpretaciones. El modelo puede ofrecer evidencia consistente con una relación propuesta, pero la fuerza de la inferencia causal dependerá del diseño, la temporalidad, el control de variables y la consistencia con estudios previos (Shmueli et al., 2016).

En investigaciones orientadas a publicación académica, la representación gráfica debe ser suficientemente clara para que el lector pueda evaluar la propuesta sin depender exclusivamente del texto. Un buen diagrama debe mostrar nombres breves de constructos, flechas legibles, dirección precisa de relaciones y organización visual coherente. **La claridad visual también forma parte del rigor científico**, porque facilita la comprensión del modelo y permite revisar su lógica con rapidez. Si el diagrama está saturado, desordenado o contiene abreviaturas no explicadas, puede generar confusión. Por ello, conviene acompañarlo con una nota o leyenda que defina las siglas utilizadas. Asimismo, cuando el modelo incluye muchas relaciones, puede ser útil presentar primero un modelo conceptual general y posteriormente un modelo estructural detallado. Esta estrategia permite que el lector comprenda la lógica global antes de revisar rutas específicas, mediaciones o moderaciones (Chin, 1998).

El diagrama del modelo también debe facilitar la posterior discusión de resultados. Cuando el modelo está bien organizado, la discusión puede seguir la misma secuencia estructural: primero se analizan los antecedentes principales, después los mecanismos mediadores, luego las condiciones moderadoras y finalmente la variable dependiente. **Una buena representación gráfica ordena no solo el análisis, sino también la escritura del estudio**. Por ejemplo, si el modelo muestra que alfabetización en IA influye en autoeficacia, que autoeficacia influye en actitud y que actitud influye en intención, la discusión puede organizarse siguiendo esa cadena. Esto permite que el lector observe cómo se confirma, debilita o modifica la lógica propuesta. En cambio, si el modelo está desordenado, la discusión tiende a convertirse en una lista de resultados sin narrativa. Por ello, el diagrama debe diseñarse pensando no solo en la estimación estadística, sino también en la interpretación académica del fenómeno (Hair et al., 2019).

En síntesis, se debe comprender que la representación gráfica del modelo es un componente central de la investigación estructural. **El diagrama integra fenómeno, constructos, hipótesis, medición y lógica relacional en una arquitectura visual verificable**. Su función no es únicamente mostrar flechas, sino demostrar coherencia interna, trazabilidad y parsimonia. Un modelo gráfico bien construido permite identificar la variable dependiente, distinguir constructos exógenos y endógenos, reconocer efectos directos e indirectos, ubicar mediadores y moderadores, y conectar cada hipótesis con una ruta estructural. Además, facilita la evaluación empírica, la presentación de resultados y la discusión científica. Por ello, antes de estimar el modelo, el investigador debe revisar si cada constructo está justificado, si cada flecha tiene hipótesis, si cada hipótesis tiene fundamento y si cada indicador corresponde al constructo adecuado. **La calidad del modelo estructural comienza con una representación gráfica clara, trazable y conceptualmente defendible** (Shmueli et al., 2016).

Conclusiones

El Capítulo 3 permite concluir que **el paso de la teoría al marco relacional no es un trámite técnico, sino una fase central de construcción científica del modelo SEM**. La teoría permite ordenar el fenómeno, seleccionar constructos, asignar funciones, establecer direccionalidad, justificar relaciones e integrar una arquitectura conceptual susceptible de evaluación empírica. Por ello, un modelo SEM no debe iniciar en el software, sino en una estructura argumentativa clara, donde cada constructo tenga una función definida y cada relación responda al problema de investigación. En este sentido, la teoría no solo proporciona conceptos, sino que permite convertirlos en relaciones defendibles dentro de un sistema estructural coherente (Chin, 1998).

Una conclusión clave es que **la variable dependiente organiza todo el modelo relacional**. Cuando el investigador identifica con claridad qué resultado desea explicar o predecir —por ejemplo, desempeño innovador, intención de uso, satisfacción, aprendizaje organizacional, sostenibilidad o adopción tecnológica— puede decidir qué variables explicativas, mediadoras o moderadoras son realmente pertinentes. Sin esta variable central, el modelo corre el riesgo de convertirse en una red dispersa de constructos sin jerarquía, sin dirección teórica y sin capacidad clara de responder la pregunta de investigación. Por ello, la variable dependiente no solo ordena el diagrama; también organiza la revisión de literatura, la formulación de hipótesis y la interpretación futura de resultados (Hair et al., 2021).

El capítulo también permite concluir que **la medición es condición previa para interpretar relaciones estructurales con rigor**. Las rutas entre constructos solo son defendibles si las variables latentes están representadas por indicadores válidos, confiables y conceptualmente pertinentes. Por ello, antes de interpretar coeficientes, efectos directos, efectos indirectos o hipótesis, el investigador debe asegurar que los constructos fueron correctamente operacionalizados mediante criterios como cargas

externas, confiabilidad interna, confiabilidad compuesta, validez convergente, validez discriminante y colinealidad. Un modelo puede tener relaciones aparentemente atractivas, pero perder valor científico si sus constructos no están adecuadamente definidos y medidos (Fornell & Larcker, 1981).

Otra conclusión relevante es que **el panorama de las técnicas SEM permite ubicar a PLS-SEM y CB-SEM dentro de una familia metodológica más amplia**. SEM no se reduce a una sola técnica ni a un software específico; incluye análisis de trayectoria, análisis factorial confirmatorio, modelos multigrupo, invariancia de medición, modelos de mediación, moderación, modelos jerárquicos, crecimiento latente, ecuaciones simultáneas, GSCA, PLSc, modelos compuestos y otras aproximaciones. No obstante, PLS-SEM y CB-SEM se desarrollan con mayor detalle porque son las dos rutas más conocidas y utilizadas en investigación aplicada con constructos latentes. CB-SEM se orienta principalmente al ajuste global y a la confirmación teórica basada en covarianzas, mientras que PLS-SEM se vincula con explicación de varianza, predicción, modelos complejos y constructos formativos o compuestos (Hair et al., 2019).

Asimismo, el capítulo muestra que **las hipótesis son la expresión evaluable del sistema conceptual**. Una hipótesis no debe formularse como una afirmación general ni como una simple expectativa intuitiva, sino como una relación precisa entre constructos, con dirección esperada, fundamento teórico y posibilidad de contraste empírico. Por ello, el análisis mediante coeficientes de trayectoria, valores t, valores p, intervalos de confianza, efectos directos, efectos indirectos y efectos totales no sustituye la teoría, sino que permite valorar si las relaciones propuestas reciben apoyo empírico dentro de una muestra, contexto e instrumento determinados. En consecuencia, una hipótesis bien formulada une teoría, medición y análisis estructural (Gefen et al., 2000).

Finalmente, el Capítulo 3 permite concluir que **la representación gráfica del modelo no es un recurso decorativo, sino una herramienta de trazabilidad científica**. Cada flecha del diagrama debe corresponder a una relación justificada; cada constructo debe tener una función dentro del sistema; **cada hipótesis debe poder rastrearse desde el problema de investigación hasta la teoría, la medición y el análisis empírico.** La coherencia interna del modelo exige que no existan relaciones redundantes, constructos sin función o rutas incorporadas solo por conveniencia estadística. De este modo, el marco relacional se convierte en el puente entre la teoría y la evaluación SEM, permitiendo que el modelo sea conceptualmente defendible, metodológicamente viable y empíricamente evaluable. **Véase la Tabla 3.2**

Tabla 3.2. De la teoría a las variables

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Alfa de Cronbach	Índice de confiabilidad interna que evalúa la consistencia entre los indicadores de un constructo reflectivo.	Permite valorar si los ítems de una escala presentan coherencia interna.	Valores ≥ .70 suelen considerarse aceptables; valores excesivamente altos pueden sugerir redundancia.	Hair et al. (2019); Hair et al. (2021)
Análisis de componentes principales / PCA	Técnica de reducción de datos que transforma variables correlacionadas en componentes lineales.	Puede apoyar análisis preliminares o construcción exploratoria de componentes.	No debe confundirse con CFA, porque PCA no confirma un modelo teórico de medición latente.	Dijkstra & Henseler (2015); Henseler (2017)
Análisis de trayectoria / *Path* analysis	Técnica que modela relaciones causales hipotéticas entre variables observadas, permitiendo estimar efectos directos, indirectos y totales.	Sirve como antecedente lógico de SEM y permite representar cadenas relacionales entre variables.	Útil cuando se trabaja con variables observadas y se desea analizar una red de dependencias.	Chin (1998); Henseler (2017)
Análisis factorial confirmatorio / CFA	Técnica orientada a confirmar si los indicadores observados representan adecuadamente los constructos latentes propuestos por la teoría.	Evalúa el modelo de medición antes de interpretar relaciones estructurales.	Permite revisar cargas factoriales, consistencia interna, validez convergente y validez discriminante.	Churchill (1979); Hair et al. (2021)
Antecedente	Variable que precede conceptualmente a otra dentro del modelo.	Explica o contribuye a explicar una consecuencia o variable dependiente.	Debe tener fundamento teórico claro y dirección justificable.	Chin (1998); Gefen et al. (2000)
AVE / IVE	Varianza media extraída; indica la proporción de varianza que un constructo explica de sus indicadores.	Evalúa la validez convergente del constructo.	AVE ≥ .50 indica que el constructo explica al menos la mitad de la varianza de sus indicadores.	Fornell & Larcker (1981); Hair et al. (2019)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Cargas externas	Relación entre cada indicador y el constructo que pretende medir.	Permiten evaluar la contribución individual de cada indicador en modelos reflectivos.	Cargas ≥ .708 son recomendables; cargas entre .40 y .70 pueden revisarse antes de eliminarse.	Hair et al. (2019); Hair et al. (2021)
CB-SEM	Modelado de ecuaciones estructurales basado en covarianzas; busca evaluar si el modelo teórico reproduce adecuadamente la matriz de covarianzas observada.	Se usa para confirmar modelos teóricos, evaluar ajuste global y trabajar con modelos reflectivos consolidados.	Pertinente cuando existe teoría madura, interés confirmatorio y necesidad de índices de ajuste global.	Hair et al. (2019); Henseler (2017)
CFI	Comparative Fit Index; índice de ajuste incremental en CB-SEM.	Evalúa qué tan bien ajusta el modelo propuesto en comparación con un modelo nulo o de referencia.	Valores ≥ .90 suelen considerarse aceptables; ≥ .95 indica ajuste más exigente.	Hair et al. (2019)
Chi-cuadrada / χ^2	Índice que evalúa la discrepancia entre la matriz de covarianzas observada y la matriz estimada por el modelo.	Es un criterio clásico de ajuste global en CB-SEM.	Una χ^2 no significativa indica menor discrepancia, aunque es sensible al tamaño de muestra.	Hair et al. (2019)
χ^2/gl	Razón entre Chi-cuadrada y grados de libertad.	Funciona como criterio relativo de ajuste global en CB-SEM.	Valores menores a 3 o 5 suelen considerarse aceptables, según el campo y la exigencia metodológica.	Hair et al. (2019)
Coeficiente de trayectoria / β	Valor que representa la fuerza y dirección de la relación entre dos constructos.	Permite evaluar hipótesis estructurales.	Se interpreta por signo, magnitud, significancia y coherencia teórica.	Chin (1998); Hair et al. (2019)
Colinealidad / VIF	Grado de redundancia o asociación excesiva entre indicadores o	Permite revisar si los predictores aportan información diferenciada al modelo.	VIF menor a 3.3 suele ser deseable; menor a 5 puede aceptarse en	Hair et al. (2019); Kock (2015)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	constructos predictores.		algunos contextos aplicados.	
Confiabilidad compuesta / CR / IFC	Índice de consistencia interna que considera las cargas de los indicadores.	Evalúa la confiabilidad de constructos reflectivos.	Valores entre .70 y .95 suelen considerarse adecuados; valores > .95 pueden indicar redundancia.	Hair et al. (2019); Hair et al. (2021)
Constructo	Concepto teórico no observable directamente que se representa mediante indicadores.	Es la unidad conceptual central del modelo SEM.	Debe definirse con precisión y distinguirse de sus indicadores.	Chin (1998); Hair et al. (2021)
Constructo formativo	Constructo formado por indicadores que funcionan como causas o componentes del concepto.	Permite modelar índices, capacidades o fenómenos multidimensionales donde los indicadores forman el constructo.	No exige alta correlación entre indicadores; se revisan pesos, relevancia y colinealidad.	Diamantopoulos & Winklhofer (2001); Hair et al. (2019)
Constructo reflectivo	Constructo latente que se manifiesta en sus indicadores observables.	Permite evaluar escalas donde los ítems reflejan una misma variable subyacente.	Se espera correlación entre indicadores, cargas externas adecuadas, confiabilidad y validez convergente.	Hair et al. (2021); Henseler et al. (2015)
Direccionalidad	Sentido teórico de la relación entre constructos.	Define qué variable antecede y cuál funciona como consecuencia.	La dirección debe justificarse teóricamente antes de estimarse estadísticamente.	Chin (1998); Gefen et al. (2000)
Efecto directo	Relación inmediata entre un constructo predictor y un constructo dependiente.	Permite estimar la influencia directa de una variable sobre otra.	Se interpreta mediante coeficiente de trayectoria, signo, magnitud y significancia.	Chin (1998); Hair et al. (2019)
Efecto indirecto	Relación entre dos constructos que ocurre mediante una variable mediadora.	Permite analizar mecanismos explicativos dentro del modelo.	Es relevante cuando se desea explicar cómo o por qué ocurre una relación.	Nitzl et al. (2016); Hair et al. (2019)
Efecto total	Suma de los efectos directos e indirectos de un	Permite valorar la influencia global de una variable dentro	Ayuda a identificar la importancia	Hair et al. (2019); Nitzl et al. (2016)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	constructo sobre otro.	del sistema estructural.	completa de un predictor en el modelo.	
f^2	Tamaño del efecto de un predictor sobre un constructo endógeno.	Complementa el R^2 al mostrar la contribución individual de cada predictor.	Valores orientativos: .02 pequeño, .15 mediano y .35 grande.	Chin (1998); Hair et al. (2019)
Grados de libertad / gl	Número de restricciones disponibles para estimar el modelo.	Forma parte de la evaluación del ajuste global en CB-SEM.	Se interpreta junto con χ^2 y otros índices de ajuste.	Hair et al. (2019)
GSCA	Generalized Structured Component Analysis; técnica SEM basada en componentes.	Permite estimar modelos estructurales mediante componentes en lugar de factores comunes.	Alternativa dentro de los enfoques SEM basados en varianza o componentes.	Dijkstra & Henseler (2015); Henseler (2017)
Hipótesis estructural	Proposición evaluable que establece una relación esperada entre constructos.	Traduce el marco relacional en relaciones susceptibles de contraste empírico.	Debe tener dirección, fundamento teórico y posibilidad de evaluación estadística.	Gefen et al. (2000); Hair et al. (2021)
HTMT	Heterotrait-Monotrait Ratio; criterio para evaluar validez discriminante.	Permite verificar si dos constructos son empíricamente distintos.	HTMT < .85 es criterio estricto; HTMT < .90 puede aceptarse en contextos más flexibles.	Henseler et al. (2015); Hair et al. (2021)
Indicador	Variable observable, ítem o medida empírica que representa un constructo.	Permite operacionalizar constructos latentes.	Debe derivarse de la definición conceptual del constructo y ser claro, pertinente y medible.	Churchill (1979); Hair et al. (2021)
Intervalo de confianza	Rango estimado dentro del cual puede ubicarse el valor poblacional de un parámetro.	Permite evaluar precisión e inferencia estadística de rutas, efectos directos e indirectos.	Si el intervalo no incluye cero, el efecto suele considerarse estadísticamente significativo.	Hair et al. (2019); Nitzl et al. (2016)
Invariancia de medición	Evaluación de si un constructo se mide de forma equivalente entre grupos.	Es condición previa para comparar grupos en modelos SEM.	Sin invariancia, las diferencias entre grupos pueden deberse a fallas de medición.	Henseler et al. (2016); Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Marco relacional	Sistema argumentativo que conecta constructos, define funciones, establece direcciones y prepara hipótesis.	Convierte la teoría en una red estructural evaluable.	Debe mostrar qué constructo se relaciona con cuál, por qué y en qué dirección.	Gefen et al. (2000); Hair et al. (2021)
Mediación	Relación en la que una variable transmite el efecto de un antecedente hacia una consecuencia.	Explica el mecanismo mediante el cual ocurre una relación.	Responde al cómo o por qué una variable influye en otra.	Nitzl et al. (2016); Hair et al. (2019)
Modelo compuesto	Modelo donde el constructo se representa como combinación ponderada de indicadores.	Permite trabajar con artefactos, capacidades, índices o configuraciones.	No presupone necesariamente una variable latente común que cause todos los indicadores.	Henseler (2017); Dijkstra & Henseler (2015)
Modelo de crecimiento latente	Modelo longitudinal que analiza trayectorias de cambio en el tiempo.	Permite estudiar evolución, punto inicial, pendiente y diferencias entre trayectorias.	Útil para analizar aprendizaje, adopción tecnológica, desempeño o cambios actitudinales.	Henseler (2017); Hair et al. (2021)
Modelo de ecuaciones simultáneas	Modelo que analiza sistemas donde las variables pueden influirse mutuamente.	Permite representar relaciones recíprocas, simultaneidad o endogeneidad.	Es pertinente cuando la causalidad no fluye en una sola dirección.	Hult et al. (2018); Dijkstra & Henseler (2015)
Modelo de medición	Parte del modelo SEM que define cómo los indicadores representan a los constructos.	Evalúa la calidad de la operacionalización de las variables latentes.	Debe revisarse antes de interpretar el modelo estructural.	Churchill (1979); Hair et al. (2021)
Modelo estructural	Parte del modelo SEM que define las relaciones entre constructos.	Permite evaluar hipótesis, efectos, dirección y capacidad explicativa o predictiva.	Debe derivarse del marco relacional y no del software.	Chin (1998); Hair et al. (2019)
Modelo jerárquico / segundo orden	Modelo donde un constructo superior se representa mediante	Permite analizar constructos multidimensionales.	Debe utilizarse cuando la teoría justifica que un constructo tiene varias dimensiones.	Hair et al. (2021); Henseler (2017)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	dimensiones de primer orden.			
Modelos MIMIC	Modelos con múltiples indicadores y múltiples causas de un constructo latente.	Permiten integrar medición y antecedentes observables de un constructo.	Útiles cuando un constructo se mide por indicadores y, además, es explicado por variables observadas.	Henseler (2017); Hair et al. (2021)
Modelos multigrupo	Modelos que comparan relaciones estructurales entre grupos.	Permiten evaluar si las relaciones del modelo cambian según población, contexto o segmento.	Deben aplicarse después de revisar invariancia de medición.	Henseler et al. (2016); Hair et al. (2021)
Moderación	Relación donde una variable modifica la intensidad o dirección entre un predictor y una variable dependiente.	Permite analizar condiciones bajo las cuales una relación cambia.	Responde al cuándo, para quién o bajo qué condiciones ocurre una relación.	Hair et al. (2019); Chin (1998)
NFI	Normed Fit Index; índice incremental de ajuste en CB-SEM.	Compara el modelo propuesto contra un modelo nulo.	Valores ≥ .90 suelen considerarse aceptables.	Hair et al. (2019)
NNFI / TLI	Non-Normed Fit Index o Tucker-Lewis Index; índice de ajuste incremental que penaliza la complejidad del modelo.	Evalúa ajuste global considerando parsimonia.	Valores ≥ .90 son aceptables; ≥ .95 indican ajuste más fuerte.	Hair et al. (2019)
p valor	Probabilidad asociada a una prueba estadística bajo la hipótesis nula.	Permite valorar si una relación, efecto o discrepancia es estadísticamente significativa.	$p < .05$ suele considerarse significativo; debe interpretarse junto con tamaño del efecto y teoría.	Gefen et al. (2000); Hair et al. (2019)
PLS-SEM	Modelado de ecuaciones estructurales por mínimos cuadrados parciales, basado en varianza y componentes.	Se orienta a explicar varianza, predecir constructos endógenos y analizar modelos complejos.	Pertinente con orientación predictiva, teoría en desarrollo, constructos formativos o compuestos.	Hair et al. (2019); Hair et al. (2021)
PLSc / consistent PLS	Extensión de PLS que corrige	Permite aproximar mejor parámetros	Útil cuando el investigador	Dijkstra & Henseler (2015)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	problemas de consistencia cuando PLS se aplica a factores comunes reflectivos.	en modelos reflectivos de factor común.	trabaja con constructos reflectivos y busca estimaciones más consistentes.	
PLSpredict	Procedimiento para evaluar capacidad predictiva en PLS-SEM.	Permite contrastar si el modelo predice adecuadamente casos no usados en la estimación.	Debe revisarse cuando el estudio declara orientación predictiva.	Shmueli et al. (2019); Hair et al. (2019)
Q²	Índice de relevancia predictiva del modelo.	Permite evaluar si el modelo tiene capacidad para predecir constructos endógenos.	Q^2 mayor que cero indica relevancia predictiva.	Shmueli et al. (2019); Hair et al. (2019)
R²	Coeficiente de determinación que indica la varianza explicada de un constructo endógeno.	Evalúa la capacidad explicativa del modelo sobre la variable dependiente.	Valores orientativos: .25 débil, .50 moderado y .75 sustancial.	Hair et al. (2019); Hair et al. (2021)
Regresión con sum scores	Uso de puntuaciones agregadas o promedios de ítems para analizarlas mediante regresión.	Puede servir como aproximación simple cuando las escalas están consolidadas.	No modela explícitamente error de medición; no sustituye plenamente a SEM.	Dijkstra & Henseler (2015); Hair et al. (2021)
RMSEA	Root Mean Square Error of Approximation; índice de error de aproximación en CB-SEM.	Evalúa el ajuste global considerando la discrepancia por grado de libertad.	RMSEA < .08 suele ser aceptable; < .06 indica ajuste más exigente.	Hair et al. (2019)
RMSE / MAE	Métricas de error predictivo usadas para valorar desempeño de predicción.	Se utilizan en evaluación predictiva, especialmente en PLSpredict.	Menores valores indican menor error predictivo; deben compararse con modelos de referencia.	Shmueli et al. (2019)
Software SEM	Herramientas computacionales para especificar, estimar y evaluar modelos SEM.	Permite implementar técnicas según la lógica metodológica elegida.	AMOS, LISREL, EQS, Mplus y lavaan se asocian con CB-SEM; SmartPLS, ADANCO, WarpPLS,	Henseler (2017); Hair et al. (2019)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
			SEMinR y cSEM con PLS-SEM.	
SRMR	Standardized Root Mean Square Residual; índice de residuales estandarizados.	Evalúa la discrepancia promedio entre correlaciones observadas y estimadas.	SRMR < .08 suele considerarse adecuado como criterio aproximado; en PLS-SEM no debe sustituir la evaluación de medición, estructura, explicación y predicción.	Henseler et al. (2015)
Teoría	Fundamento conceptual que permite ordenar el fenómeno, seleccionar constructos, justificar relaciones y formular hipótesis.	Da sentido al modelo antes del software.	Una relación estructural debe incluirse porque la teoría la justifica, no porque el software la permita.	Chin (1998); Gefen et al. (2000)
Valor t	Estadístico que permite evaluar si un coeficiente estimado difiere significativamente de cero.	Se usa para contrastar hipótesis estructurales.	Valores t superiores a 1.96 suelen asociarse con significancia al 5% en pruebas bilaterales.	Hair et al. (2019)
Validez convergente	Grado en que los indicadores de un constructo convergen en la medición del mismo concepto.	Permite verificar si los ítems representan adecuadamente el constructo.	Se evalúa principalmente mediante AVE ≥ .50 en modelos reflectivos.	Fornell & Larcker (1981); Hair et al. (2019)
Validez discriminante	Grado en que un constructo es distinto de otros constructos del modelo.	Protege la identidad conceptual y empírica de cada variable latente.	Puede evaluarse mediante HTMT, Fornell-Larcker o cargas cruzadas.	Fornell & Larcker (1981); Henseler et al. (2015)
Variable dependiente	Constructo resultado que se desea explicar o predecir.	Organiza todo el modelo estructural y define el eje de análisis.	Puede ser desempeño innovador, intención de uso, satisfacción, aprendizaje organizacional, sostenibilidad o adopción tecnológica.	Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Variables explicativas	Constructos antecedentes que ayudan a explicar o predecir la variable dependiente.	Funcionan como predictores dentro del modelo estructural.	Deben incluirse solo si tienen relación teórica clara con el resultado central.	Chin (1998); Hair et al. (2019)

Fuente: recopilación y elaboración propia

CAPÍTULO 4. Del concepto al constructo medible

El Capítulo 4 desarrolla el tránsito entre la **formulación conceptual** y la **construcción de constructos medibles**. En esta etapa, el investigador ya no solo define ideas generales, sino que debe precisar cómo esas ideas se convierten en variables, constructos, dimensiones e indicadores. Esta distinción es fundamental porque un modelo SEM no se sostiene únicamente en relaciones teóricas, sino en la capacidad de representar empíricamente fenómenos abstractos. Por ello, el capítulo inicia con la aclaración de la diferencia entre **concepto, variable y constructo**, como base para evitar ambigüedades y errores de especificación (Churchill, 1979).

A partir de esa base, el capítulo explica que muchos fenómenos administrativos no pueden observarse directamente. La confianza, la satisfacción, el aprendizaje organizacional, la cultura innovadora o la capacidad digital son **constructos latentes** que requieren ser inferidos mediante **variables observables**. Esta relación entre lo abstracto y lo empírico es central para SEM, porque los indicadores no son el

constructo en sí, sino aproximaciones que deben representar adecuadamente su dominio conceptual. Si esta conexión es débil, el modelo puede producir resultados estadísticos, **pero tendrá baja capacidad interpretativa** (Jarvis et al., 2003).

El capítulo también aborda la **dimensionalidad del constructo**, es decir, la decisión de tratarlo como una entidad unidimensional, multidimensional o jerárquica. Esta decisión debe surgir de la teoría y del propósito del estudio, no solo del análisis estadístico. Definir la dimensionalidad permite evitar dos errores frecuentes: reducir demasiado constructos complejos o fragmentarlos sin necesidad. Así, antes de redactar indicadores, el investigador debe comprender si el constructo expresa una sola idea central o si integra varias dimensiones que deben representarse de manera diferenciada (Hair et al., 2021).

Después, el capítulo avanza hacia el **desarrollo inicial de escalas**, entendido como la traducción del constructo en indicadores claros, pertinentes y respondibles. Una escala no debe surgir de una lista improvisada de preguntas, sino de una correspondencia entre definición conceptual, dimensiones, indicadores, informante, contexto y escala de respuesta. Por ello, se insiste en que la calidad del modelo SEM depende en gran medida de la calidad con que fueron diseñadas las escalas. **Sin una escala bien construida, el modelo estructural pierde fuerza**, aunque posteriormente arroje resultados aparentemente aceptables (Henseler, 2017).

Finalmente, el capítulo cierra con la **especificación conceptual antes de medir**, una fase de control previo que permite verificar si el constructo, sus dimensiones, sus indicadores y su forma de medición están alineados. Esta revisión evita mezclar antecedentes con resultados, confundir dimensiones con indicadores o medir constructos mal delimitados. La idea central del capítulo es clara: **antes de medir, hay que especificar; antes de estimar, hay que alinear; antes de interpretar, hay que saber exactamente qué se midió** (Hair et al., 2021).

Concepto, variable, constructo

El paso de la teoría al modelo SEM exige distinguir con precisión entre **concepto**, **variable** y **constructo**, porque cada uno cumple una función distinta dentro del proceso de investigación. Un **concepto** permite nombrar una idea general o un fenómeno de interés; una **variable** expresa una propiedad que puede variar entre casos; y un **constructo** representa una entidad teórica que no se observa directamente, pero que puede ser inferida mediante indicadores. Esta distinción es esencial porque un modelo estructural no se construye con palabras generales, sino con conceptos transformados en entidades medibles. Por ejemplo, “innovación” puede iniciar como concepto amplio; “desempeño innovador” puede formularse como variable resultado; y “capacidad de innovación” puede convertirse en constructo latente si se representa mediante indicadores. Cuando el investigador no diferencia estos niveles, corre el riesgo de construir modelos ambiguos, con relaciones difíciles de interpretar. Por ello, antes de seleccionar ítems o dibujar flechas, debe preguntarse qué tipo de entidad está utilizando: **una idea conceptual, una propiedad variable o un**

constructo latente. Esta claridad inicial permite pasar de la teoría a la medición con mayor rigor (Churchill, 1979).

Un **concepto** es el punto de partida del pensamiento científico, pero todavía no constituye una unidad empírica lista para el análisis. En ciencias de la administración, conceptos como **liderazgo**, **confianza**, **sostenibilidad**, **aprendizaje organizacional**, **transformación digital**, **orientación al mercado** o **desempeño** ayudan a nombrar fenómenos relevantes, pero suelen ser demasiado amplios si no se delimitan. Por ejemplo, transformación digital puede referirse a adopción tecnológica, automatización, cultura digital, capacidades analíticas, rediseño de procesos o nuevos modelos de negocio. Si el investigador no precisa qué dimensión abordará, el concepto queda abierto y puede generar confusión en el modelo. Delimitar un concepto significa definir qué se incluye, qué se excluye y desde qué perspectiva se estudiará. Esta delimitación no empobrece el fenómeno; lo vuelve investigable. Un concepto amplio puede inspirar una investigación, pero para convertirse en parte de un modelo SEM debe adquirir forma conceptual precisa. De lo contrario, las hipótesis serán vagas, los indicadores serán heterogéneos y la interpretación de resultados será débil. La claridad conceptual es, por tanto, el primer criterio de calidad antes de cualquier medición (Jarvis et al., 2003).

La **variable** representa una propiedad que puede asumir distintos valores entre unidades de análisis. Algunas variables son directamente observables, como edad, antigüedad, número de empleados, años de operación o ventas. Otras requieren medición indirecta porque se refieren a percepciones, actitudes, capacidades o evaluaciones. En administración, una variable puede ser satisfacción, intención de uso, desempeño innovador, confianza, cultura organizacional o aprendizaje. La diferencia central es que una variable debe expresar variación: no todos los casos tienen el mismo nivel de satisfacción, confianza o desempeño. Esta variación es lo que permite analizar relaciones. Sin embargo, no toda variable tiene la misma naturaleza. Algunas pueden medirse con un solo dato observable; otras necesitan varios indicadores para representar un constructo latente. Por ejemplo, “número de empleados” puede medirse directamente; “confianza organizacional” requiere ítems que capten distintas manifestaciones. Esta distinción es clave para SEM, porque el investigador debe decidir si trabaja con variables observadas o con constructos latentes. Confundir ambos niveles puede llevar a mediciones insuficientes o modelos mal especificados (Hair et al., 2021).

El **constructo** es una entidad teórica que se utiliza cuando el fenómeno de interés no puede observarse directamente. Constructos como **confianza**, **compromiso**, **calidad percibida**, **orientación emprendedora**, **aprendizaje organizacional**, **capacidad dinámica** o **cultura innovadora** no aparecen como datos inmediatos; se infieren mediante indicadores. Por ejemplo, la confianza puede representarse mediante ítems sobre credibilidad, seguridad, cumplimiento de expectativas o percepción de honestidad. El constructo permite vincular teoría y medición: por un lado, conserva una definición abstracta; por otro, exige una representación empírica. En SEM, esta relación es crucial porque el modelo de medición establece cómo los

indicadores representan al constructo, mientras el modelo estructural analiza cómo los constructos se relacionan entre sí. Si el constructo está mal definido, los resultados posteriores pierden sentido, aunque los índices sean aparentemente aceptables. Por ello, la construcción del constructo exige claridad sobre su significado, alcance, dimensiones y relación con otros constructos. Un modelo SEM sólido requiere constructos conceptualmente consistentes antes de evaluar cualquier relación estadística (Henseler, 2017).

La diferencia entre **concepto** y **constructo** puede entenderse como el tránsito de una idea amplia hacia una entidad teóricamente delimitada y medible. El concepto permite pensar; el constructo permite modelar. Por ejemplo, “sostenibilidad” es un concepto amplio; “orientación sostenible de la empresa” puede convertirse en constructo si se define con precisión y se representa mediante indicadores. De igual forma, “innovación” puede ser un concepto general, pero “desempeño innovador” puede transformarse en constructo si se especifican sus manifestaciones: nuevos productos, mejoras de procesos, generación de soluciones o introducción de prácticas novedosas. Este tránsito no consiste únicamente en cambiar el nombre del concepto, sino en construir una definición operativa y teórica que permita decidir qué indicadores corresponden y cuáles no. Un error frecuente consiste en usar conceptos amplios como si ya fueran constructos listos para el análisis. Esto debilita el modelo, porque el investigador no sabe exactamente qué está midiendo. La conversión de concepto a constructo requiere **definición, delimitación, dimensionalidad y posibilidad de medición**. Solo así el concepto adquiere valor dentro de un sistema SEM (Churchill, 1979).

También debe distinguirse entre variable y constructo. Toda variable implica variación, pero no toda variable es un constructo latente. Algunas variables pueden observarse directamente, como edad, tamaño de empresa o años de experiencia. Otras representan constructos no observables, como satisfacción, confianza, cultura innovadora o orientación al mercado. Esta diferencia afecta el diseño del modelo. Una variable observable puede incorporarse como dato directo, variable de control o indicador simple. Un constructo latente requiere un conjunto de indicadores y una lógica de medición. Por ejemplo, medir “número de empleados” mediante varios ítems sería innecesario, porque se trata de un dato observable; en cambio, medir “satisfacción” con una sola pregunta puede resultar insuficiente si el constructo es complejo. El investigador debe preguntarse: **¿esto puede observarse directamente o requiere inferencia mediante indicadores?**. Esta pregunta ayuda a decidir si se necesita un constructo latente o una variable observada. La correcta distinción entre variable y constructo evita errores de especificación y prepara una medición más coherente (Jarvis et al., 2003).

La definición del constructo debe ser suficientemente precisa para indicar si será unidimensional o **multidimensional**. Un constructo unidimensional representa una sola dimensión conceptual; sus indicadores apuntan hacia una idea central. En cambio, un constructo multidimensional integra varias dimensiones relacionadas. Por ejemplo, la calidad del servicio puede incluir confiabilidad, capacidad de respuesta,

seguridad, empatía y tangibles. La transformación digital puede incluir infraestructura tecnológica, cultura digital, capacidades analíticas y rediseño de procesos. Esta decisión no debe dejarse únicamente al análisis estadístico, porque la dimensionalidad también es una decisión teórica. Si se mezclan dimensiones diferentes sin reconocerlas, el constructo puede volverse ambiguo. Si se separan dimensiones que conceptualmente pertenecen a una misma entidad, el modelo puede fragmentarse innecesariamente. Por ello, el investigador debe analizar si el constructo representa una sola idea o si integra varios componentes. Esta decisión tendrá consecuencias en la selección de indicadores, en la especificación del modelo de medición y en la interpretación de resultados. La dimensionalidad debe nacer de la teoría antes de ser evaluada empíricamente (Hair et al., 2021).

Un problema frecuente es la sobreamplitud conceptual. Esto ocurre cuando el constructo se define de manera tan amplia que incluye demasiados significados. Por ejemplo, si "desempeño organizacional" incluye rentabilidad, productividad, innovación, reputación, satisfacción, impacto social y sostenibilidad, el constructo se vuelve difícil de medir e interpretar. Algo similar ocurre con "transformación digital" cuando se mezclan tecnologías, procesos, cultura, estrategia, habilidades, modelos de negocio y resultados. La sobreamplitud produce indicadores heterogéneos, relaciones ambiguas y dificultades para interpretar el modelo. Para evitarlo, el investigador debe delimitar el constructo según el propósito del estudio. Si el interés es innovación, puede trabajar con desempeño innovador; si el interés es eficiencia, con desempeño operativo; si el interés es impacto ambiental, con desempeño sostenible. Esta precisión no reduce la importancia del fenómeno; la vuelve investigable. En SEM, un constructo demasiado amplio puede afectar la calidad del modelo de medición y la claridad de las relaciones estructurales. La delimitación conceptual es, por tanto, una forma de rigor (Henseler, 2017).

También puede presentarse el problema contrario: la sobrefragmentación conceptual. Esta ocurre cuando el investigador divide un fenómeno en demasiados constructos pequeños, generando un modelo innecesariamente complejo. Por ejemplo, puede separar "uso tecnológico", "habilidad digital", "capacidad digital", "madurez digital" y "transformación digital" sin explicar claramente sus diferencias. Aunque cada término puede tener matices, incorporarlos todos en un mismo modelo puede generar redundancia. La sobrefragmentación dificulta la lectura del modelo, aumenta el número de relaciones y puede producir solapamientos conceptuales. El investigador debe equilibrar precisión y parsimonia. No todo matiz debe convertirse en constructo independiente. Algunos elementos pueden funcionar como dimensiones, indicadores o variables de control. La pregunta clave es: **¿este concepto necesita ser un constructo separado o puede integrarse dentro de otro?**. Esta decisión debe tomarse con base en teoría, problema de investigación y propósito del modelo. Un modelo SEM de calidad no solo diferencia conceptos; también evita fragmentarlos sin necesidad. La claridad surge del equilibrio entre distinción y síntesis conceptual (Jarvis et al., 2003).

La definición del constructo debe tener coherencia con la unidad de análisis. Si el estudio se realiza en individuos, el constructo debe formularse a nivel individual; si se realiza en empresas, debe formularse a nivel organizacional. Por ejemplo, la **confianza en una plataforma digital** puede medirse a nivel individual, mientras que la **capacidad de innovación organizacional** exige información a nivel empresa. Un error frecuente consiste en definir constructos organizacionales, pero medirlos únicamente con percepciones individuales sin justificar cómo esas respuestas representan a la organización. Esto puede debilitar el modelo porque mezcla niveles de análisis. El investigador debe indicar si los indicadores representan percepciones personales, atributos colectivos, prácticas organizacionales o resultados institucionales. Esta coherencia es esencial para interpretar correctamente las relaciones estructurales. Si un constructo se define a nivel organizacional, sus indicadores deben capturar atributos de la organización. Si se define a nivel individual, sus indicadores deben capturar percepciones, actitudes o comportamientos individuales. La claridad entre constructo y unidad de análisis evita inferencias indebidas y fortalece la validez conceptual del modelo (Hair et al., 2021).

La construcción del constructo también requiere establecer **límites conceptuales** frente a constructos cercanos. En administración, varios conceptos pueden parecer similares, pero representar fenómenos distintos. Por ejemplo, **satisfacción**, **confianza**, **compromiso** y **lealtad** pueden relacionarse en estudios de comportamiento del consumidor, pero no deben tratarse como equivalentes. Del mismo modo, **capacidad digital**, **madurez digital** y **transformación digital** pueden formar parte del mismo campo, pero no necesariamente son el mismo constructo. Si el investigador no diferencia estos límites, puede generar problemas de solapamiento conceptual. Esta diferenciación debe ocurrir antes de cualquier evaluación estadística. Más adelante, criterios como la validez discriminante ayudarán a revisar empíricamente si los constructos se distinguen, pero la primera separación debe ser teórica. El investigador debe responder: **¿qué significa este constructo?, ¿qué no significa?, ¿en qué se diferencia de otros constructos cercanos?, ¿por qué merece ser tratado como entidad separada?**. Esta delimitación fortalece el modelo y evita relaciones tautológicas entre variables que, en realidad, podrían estar midiendo casi lo mismo (Jarvis et al., 2003).

Un constructo debe definirse con suficiente claridad para orientar la selección de indicadores. Los indicadores no deben elegirse solo porque aparecen en escalas previas o porque son fáciles de redactar; deben representar el contenido conceptual del constructo. Por ejemplo, si se define **aprendizaje organizacional** como la capacidad de adquirir, compartir e integrar conocimiento, los indicadores deben reflejar esas dimensiones. Si solo se incluyen ítems sobre capacitación, el constructo quedaría reducido artificialmente. De igual modo, si se define **capacidad digital** como uso estratégico de tecnologías, no bastaría con preguntar si la organización utiliza computadoras o redes sociales. La definición conceptual debe guiar qué señales observables serán pertinentes. Esta lógica es central porque la calidad de los indicadores depende de la claridad del constructo. Un constructo mal definido permite indicadores dispersos; un constructo bien delimitado orienta indicadores coherentes.

En SEM, la medición no comienza con el software, sino con la decisión de qué manifestaciones representan adecuadamente el concepto. Por ello, el investigador debe construir primero una definición robusta y después derivar indicadores consistentes (Churchill, 1979).

La relación entre constructo e indicador también exige reconocer que los indicadores son **representaciones parciales**, no equivalentes perfectos del constructo. Ningún conjunto de ítems captura por completo fenómenos complejos como confianza, cultura, innovación o aprendizaje. Los indicadores aproximan empíricamente una dimensión del constructo. Esta idea es importante porque evita interpretar los resultados como si fueran la realidad completa. Por ejemplo, tres ítems sobre confianza no agotan toda la confianza; solo representan una parte definida por el investigador. De ahí la importancia de que la definición conceptual sea clara y de que los indicadores sean seleccionados con cuidado. Si el constructo es amplio, puede requerir varias dimensiones; si es específico, puede representarse con menos indicadores. El investigador debe equilibrar **cobertura conceptual** y **parsimonia de medición**. Incluir demasiados indicadores puede hacer el instrumento pesado; incluir pocos o mal alineados puede reducir la calidad del constructo. La selección de indicadores debe buscar correspondencia entre teoría y medición. Esta correspondencia será evaluada posteriormente, pero su origen está en la definición conceptual inicial (Henseler, 2017).

Una decisión central consiste en reconocer si el constructo se comportará como reflectivo, formativo o compuesto, aunque su desarrollo técnico se profundice en capítulos posteriores. En un constructo reflectivo, los indicadores son manifestaciones del constructo; por ejemplo, distintos ítems pueden reflejar satisfacción o confianza. En un constructo formativo, los indicadores contribuyen a formar el constructo; por ejemplo, distintos recursos, capacidades o dimensiones pueden integrar una capacidad organizacional. En un constructo compuesto, los indicadores funcionan como componentes que integran una entidad analítica construida para el modelo. La decisión no debe tomarse por comodidad estadística, sino por lógica conceptual. El investigador debe preguntarse: **¿los indicadores son efectos del constructo o partes que lo forman?**. Esta pregunta tiene consecuencias importantes en la evaluación posterior. Aunque aquí no se agotan criterios técnicos, sí se establece que la especificación comienza en la teoría. Un error en esta decisión puede afectar todo el modelo. Por ello, el tránsito de concepto a constructo también implica anticipar la lógica de medición que será coherente con su naturaleza (Hair et al., 2021).

El constructo debe mantener **coherencia semántica** a lo largo de todo el estudio. Esto significa que el investigador no debe definirlo de una manera en el marco teórico, medirlo de otra y discutirlo después con un significado distinto. Por ejemplo, si se define **desempeño innovador** como introducción de nuevos productos y procesos, no debe interpretarse posteriormente como desempeño financiero general. Si se define **transformación digital** como cambio estratégico organizacional, no debe medirse únicamente como uso de herramientas digitales básicas. Esta incoherencia genera confusión y debilita la validez del estudio. La coherencia semántica exige que el

nombre del constructo, su definición, sus indicadores y su interpretación estén alineados. En SEM, esta alineación es fundamental porque los resultados estadísticos dependen de lo que se decidió medir. Si el constructo cambia de significado durante el estudio, los coeficientes pierden sentido. Por ello, una buena práctica consiste en redactar una definición operativa breve y mantenerla como referencia durante todo el diseño. La estabilidad conceptual es una condición silenciosa, pero esencial, de la calidad metodológica (Jarvis et al., 2003).

La transformación de concepto a constructo también implica revisar la **pertinencia contextual**. Un constructo no siempre conserva exactamente el mismo significado en todos los contextos. Por ejemplo, la **innovación** puede expresarse de manera distinta en una empresa tecnológica, una pyme familiar, una universidad o una organización pública. La **capacidad digital** puede depender del sector, del tamaño de la organización, de los recursos disponibles y de la madurez tecnológica. Por ello, al definir un constructo, el investigador debe considerar el contexto empírico donde será aplicado. Esto no significa cambiar arbitrariamente el significado de los conceptos, sino adaptar con cuidado su definición y sus indicadores al entorno de estudio. Una escala desarrollada para grandes corporaciones puede no ser adecuada para microempresas; una medición pensada para consumidores digitales puede no funcionar igual en organizaciones públicas. La pertinencia contextual fortalece la validez del constructo porque asegura que el concepto tenga sentido para los sujetos de estudio. En investigación administrativa, el contexto no solo delimita la muestra; también influye en cómo se entiende y mide cada constructo (Henseler, 2017).

Un constructo también debe ser nomológicamente coherente, es decir, debe ubicarse de manera razonable dentro de una red de relaciones. Esto significa que su definición debe permitir anticipar con qué otros constructos podría relacionarse y por qué. Por ejemplo, si se define **confianza** como percepción de credibilidad y seguridad, es razonable relacionarla con intención de uso, satisfacción o lealtad. Si se define **aprendizaje organizacional** como adquisición e integración de conocimiento, puede relacionarse con innovación, adaptación o desempeño. Esta coherencia ayuda a construir hipótesis y evita relaciones arbitrarias. Un constructo no debe definirse de forma aislada; debe comprenderse dentro del sistema conceptual del estudio. Si su lugar en la red es ambiguo, quizá su definición todavía no está madura. En SEM, la red de relaciones es tan importante como la medición individual del constructo. La teoría debe mostrar no solo qué significa el constructo, sino también qué papel desempeña dentro del modelo. Esta ubicación nomológica prepara el tránsito hacia modelos estructurales más claros y defendibles (Churchill, 1979).

La definición del constructo debe evitar el uso de etiquetas atractivas pero imprecisas. En temas contemporáneos, es común encontrar términos como transformación digital, innovación disruptiva, agilidad estratégica, inteligencia organizacional o sostenibilidad integral. Aunque estos términos pueden ser relevantes, también pueden ser ambiguos si no se delimitan. Un nombre atractivo no garantiza claridad conceptual. Por ejemplo, “agilidad estratégica” puede referirse a rapidez de respuesta, flexibilidad organizacional, toma de decisiones o capacidad de

reconfiguración. Si no se define con precisión, los indicadores podrían capturar aspectos distintos. El investigador debe resistir la tentación de usar etiquetas de moda sin especificar su contenido. La pregunta central es: **¿qué fenómeno exacto representa este constructo y cómo se diferenciará de otros?**. Una etiqueta imprecisa puede hacer que el modelo parezca actualizado, pero metodológicamente débil. En cambio, una definición clara, aunque menos llamativa, fortalece la investigación. El rigor conceptual debe tener prioridad sobre la novedad terminológica aparente (Jarvis et al., 2003).

También es necesario distinguir entre constructos teóricos y variables de control. Algunos elementos pueden ser relevantes para el modelo, pero no necesariamente deben tratarse como constructos centrales. Por ejemplo, tamaño de empresa, antigüedad, sector, nivel educativo o experiencia previa pueden influir en un resultado, pero quizá funcionen mejor como variables de control. En cambio, constructos como confianza, aprendizaje, cultura o capacidades suelen formar parte del argumento teórico principal. Confundir controles con constructos centrales puede sobrecargar el modelo. El investigador debe decidir qué variables forman parte de la explicación central y cuáles solo ayudan a controlar diferencias. Esta distinción mejora la claridad del diseño. Un constructo teórico debe tener una función sustantiva en el modelo; una variable de control cumple una función auxiliar. En SEM, esta diferencia ayuda a evitar modelos innecesariamente complejos y permite concentrar la argumentación en las relaciones principales. La selección de constructos no debe hacerse por acumulación, sino por función dentro del problema de investigación (Hair et al., 2021).

El proceso de construcción conceptual también requiere revisar la **viabilidad de respuesta**. Un constructo puede estar bien definido desde la teoría, pero ser difícil de medir si los informantes no pueden responder con conocimiento suficiente. Por ejemplo, preguntar a empleados operativos sobre estrategia digital corporativa puede generar respuestas poco confiables si no conocen las decisiones estratégicas. Preguntar a consumidores sobre procesos internos de innovación de una empresa también sería inadecuado. Por ello, al definir un constructo, el investigador debe considerar quién responderá y si esa persona tiene información pertinente. Esta revisión conecta el constructo con la unidad de análisis y con el diseño del instrumento. Un constructo no solo debe ser teóricamente claro; debe ser **respondible**. Si los sujetos de estudio no pueden evaluar el contenido del constructo, los datos serán débiles. Esta preocupación es especialmente relevante en ciencias de la administración, donde muchos constructos se miden mediante percepciones. La calidad de la medición depende de que el informante tenga experiencia, conocimiento o posición adecuada para responder (Churchill, 1979).

Finalmente, el tema establece una idea central: **el modelo SEM no inicia con indicadores, sino con conceptos correctamente transformados en constructos**. Antes de evaluar cargas, AVE, HTMT, VIF o cualquier otro criterio técnico, el investigador debe saber qué significa cada constructo, cómo se diferencia de otros, qué nivel de análisis representa y por qué puede medirse mediante ciertos indicadores.

Una medición técnicamente aceptable no compensa una definición conceptual débil. Si el constructo está mal delimitado, los resultados serán difíciles de interpretar, aunque los índices parezcan adecuados. Por ello, el tránsito de concepto a variable y de variable a constructo es una fase metodológica indispensable. Este tema prepara el avance hacia los siguientes apartados del capítulo, donde se profundizará en **constructos latentes**, **variables observables**, **dimensionalidad**, **desarrollo inicial de escalas** y **especificación conceptual antes de medir**. La base es clara: primero se piensa el constructo; después se mide; finalmente se evalúa. Esta secuencia protege la coherencia del modelo y fortalece la calidad del análisis estructural (Henseler, 2017).

Constructos latentes y variables observables

Los modelos de ecuaciones estructurales parten de una idea fundamental: gran parte de los fenómenos relevantes en ciencias de la administración no pueden observarse directamente. Conceptos como **confianza**, **compromiso**, **aprendizaje organizacional**, **orientación emprendedora**, **satisfacción**, **cultura organizacional**, **capacidad de innovación** o **transformación digital** no aparecen como datos inmediatos y visibles. Lo que el investigador puede observar son señales empíricas relacionadas con esos fenómenos. Por ello, SEM trabaja con dos niveles distintos pero complementarios: el nivel de los **constructos latentes** y el nivel de las **variables observables**. El constructo latente pertenece al plano teórico; la variable observable pertenece al plano empírico. Esta distinción es esencial porque el análisis estructural no estudia directamente la realidad abstracta, sino representaciones medibles de ella. Cuando el investigador ignora esta diferencia, puede terminar confundiendo un concepto amplio con un indicador aislado. Comprender la relación entre lo latente y lo observable es, por tanto, una condición indispensable antes de interpretar cualquier coeficiente, carga factorial o relación estructural. El modelo SEM existe precisamente para conectar teoría y evidencia empírica dentro de una misma arquitectura analítica (Churchill, 1979).

Un **constructo latente** es una entidad conceptual que no puede observarse de manera directa, pero cuya existencia se infiere mediante indicadores. En ciencias sociales y administrativas, muchos fenómenos importantes pertenecen a esta categoría porque representan percepciones, capacidades, evaluaciones, creencias, procesos organizacionales o comportamientos complejos. Por ejemplo, la satisfacción del cliente no puede verse físicamente; se infiere mediante respuestas relacionadas con expectativas, experiencias y evaluación general del servicio. La confianza organizacional tampoco se observa como un objeto; se deduce mediante percepciones de credibilidad, honestidad, seguridad o cumplimiento. Así, el constructo latente funciona como una representación teórica de un fenómeno abstracto. Su valor reside en que permite organizar el pensamiento científico y convertir ideas complejas en entidades modelables. Sin embargo, el constructo no debe tratarse como una simple etiqueta elegante. Debe tener significado conceptual claro, delimitación teórica y posibilidad de representación empírica. Un constructo mal definido produce

indicadores ambiguos y relaciones débiles. Por ello, antes de construir escalas o seleccionar software, el investigador debe precisar qué significa exactamente el constructo y cómo se diferencia de otros cercanos (Jarvis et al., 2003).

Las **variables observables**, en cambio, son datos concretos que pueden registrarse directamente. Pueden expresarse como respuestas en cuestionarios, frecuencias, conteos, registros administrativos o indicadores objetivos. En estudios basados en escalas tipo Likert, cada ítem representa una variable observable. Por ejemplo, para medir satisfacción, un ítem puede preguntar si el servicio cumplió las expectativas; otro puede evaluar la experiencia general; otro puede valorar la disposición a recomendar. **Cada respuesta registrada funciona como evidencia parcial del constructo latente.** Esto significa que la variable observable no es el constructo en sí, sino una manifestación o componente de él. Esta diferencia protege al investigador de interpretar los indicadores como equivalentes absolutos del fenómeno teórico. Ningún indicador individual agota por completo el significado del constructo. Por ello, la selección de variables observables exige cuidado conceptual. Los indicadores deben ser claros, pertinentes y coherentes con la definición del constructo. Si los ítems son ambiguos, redundantes o desconectados del concepto, la representación empírica será débil. La calidad del modelo de medición depende directamente de la calidad de las variables observables seleccionadas (Hair et al., 2021).

La relación entre constructos latentes y variables observables puede entenderse como una relación entre lo abstracto y lo empírico. El investigador desea estudiar fenómenos complejos que no son visibles directamente; para ello necesita indicadores que funcionen como señales observables. Por ejemplo, si desea estudiar aprendizaje organizacional, no puede observar “el aprendizaje” como objeto físico. Lo que sí puede observar son prácticas relacionadas con compartir conocimiento, documentar experiencias, aplicar lecciones aprendidas o promover capacitación. Estas prácticas se convierten en variables observables que permiten inferir la existencia y el nivel del constructo. Esta lógica es central en SEM porque permite integrar teoría y medición dentro de un mismo sistema. Sin embargo, esta integración exige coherencia. Los indicadores deben representar el contenido conceptual del constructo y no dimensiones ajenas. Si un constructo se define como capacidad digital estratégica, sus indicadores no deberían limitarse únicamente a uso básico de software. El tránsito entre teoría y observación requiere consistencia conceptual. Las variables observables deben actuar como puente entre el fenómeno abstracto y los datos empíricos disponibles para el análisis (Henseler, 2017).

Los constructos latentes son especialmente importantes en administración porque gran parte de los fenómenos organizacionales no son directamente cuantificables. Variables como edad, ventas o número de empleados pueden medirse de manera objetiva y directa; pero constructos como compromiso, orientación al mercado o innovación organizacional requieren inferencia conceptual. Esto explica por qué SEM se ha convertido en una herramienta ampliamente utilizada en estudios administrativos y de comportamiento organizacional. El modelo permite trabajar

simultáneamente con fenómenos abstractos y relaciones estructurales complejas. No obstante, el uso de constructos latentes también implica responsabilidad metodológica. El investigador no puede inventar constructos arbitrariamente ni asumir que cualquier conjunto de ítems representa adecuadamente un fenómeno. Un constructo debe derivarse de teoría, evidencia previa y delimitación conceptual rigurosa. Además, debe poder representarse mediante variables observables coherentes. La ventaja de SEM no radica únicamente en estimar relaciones, sino en reconocer explícitamente que muchos fenómenos importantes son latentes y requieren representación indirecta (Hair et al., 2021).

La construcción de variables observables exige comprender que los indicadores no son neutrales. Cada ítem refleja una decisión conceptual sobre cómo representar el fenómeno. Por ejemplo, si la satisfacción se mide mediante preguntas sobre rapidez del servicio, amabilidad y cumplimiento de expectativas, el investigador está definiendo implícitamente qué entiende por satisfacción. Esto significa que los indicadores también comunican teoría. Un constructo puede cambiar sustancialmente según los indicadores seleccionados. Por ello, las variables observables no deben elegirse solo porque aparecen en investigaciones previas o porque resultan fáciles de aplicar. Deben corresponder al significado conceptual definido para el estudio. Además, el investigador debe evitar incluir indicadores solo por cantidad. Un modelo con muchos ítems mal alineados conceptualmente puede ser más débil que uno con menos indicadores bien seleccionados. La calidad de la medición depende menos del volumen y más de la coherencia entre constructo e indicadores. En SEM, las variables observables deben actuar como representaciones consistentes del fenómeno teórico, no como preguntas aisladas sin integración conceptual (Churchill, 1979).

Una característica importante de los constructos latentes es que suelen presentar múltiples manifestaciones. Esto significa que un mismo fenómeno puede expresarse de distintas maneras observables. Por ejemplo, el compromiso organizacional puede reflejarse en identificación con la empresa, disposición al esfuerzo adicional, deseo de permanencia y sentido de pertenencia. La confianza puede manifestarse en credibilidad, seguridad, honestidad percibida y cumplimiento de expectativas. La innovación organizacional puede expresarse mediante nuevos productos, mejora de procesos o introducción de tecnologías. Estas múltiples manifestaciones justifican el uso de varios indicadores para representar el constructo. Si solo se utilizara un indicador, podría capturarse una dimensión limitada del fenómeno. Sin embargo, también debe evitarse la acumulación excesiva de indicadores redundantes. El investigador debe seleccionar aquellos que cubran adecuadamente el dominio conceptual del constructo sin volver innecesariamente extenso el instrumento. La representación adecuada de múltiples manifestaciones es uno de los principales desafíos del modelo de medición en SEM (Jarvis et al., 2003).

La relación entre constructos latentes y variables observables también puede entenderse desde la dirección de influencia conceptual. En algunos casos, el constructo se considera la causa de los indicadores; en otros, los indicadores se consideran componentes que forman el constructo. Cuando los indicadores son

manifestaciones del constructo, se espera que estén correlacionados porque reflejan la misma entidad subyacente. Por ejemplo, si una persona está satisfecha, tenderá a responder positivamente en distintos ítems relacionados con satisfacción. En otros casos, el constructo se entiende como integración de componentes diferentes. Por ejemplo, una capacidad digital organizacional puede construirse mediante infraestructura tecnológica, habilidades digitales, integración de datos y uso estratégico de herramientas. En esta lógica, los indicadores no son efectos del constructo, sino elementos que lo conforman. Esta distinción es central en SEM porque afecta la especificación y evaluación posterior del modelo. Aunque su desarrollo técnico se profundizará más adelante, desde ahora debe quedar claro que la naturaleza de la relación entre constructo e indicador depende de la teoría del fenómeno estudiado (Hair et al., 2021).

La correcta definición de variables observables requiere atender la claridad semántica. Un indicador debe estar redactado de manera comprensible para la población objetivo. Si el lenguaje es ambiguo, excesivamente técnico o confuso, la calidad de las respuestas disminuirá. Por ejemplo, un ítem sobre capacidades analíticas avanzadas puede resultar difícil de interpretar para pequeñas empresas con bajo nivel tecnológico. Del mismo modo, preguntas sobre procesos estratégicos complejos pueden ser problemáticas si los respondentes no participan en esas decisiones. La claridad semántica implica utilizar palabras apropiadas para el contexto y la unidad de análisis. También exige evitar preguntas dobles, afirmaciones demasiado generales o términos interpretables de múltiples maneras. Un indicador bien redactado facilita que la variable observable represente realmente el constructo. Un indicador ambiguo introduce ruido en la medición. La calidad de un modelo SEM depende en gran medida de decisiones aparentemente simples como la redacción de los ítems (Churchill, 1979).

Otro aspecto importante es la **coherencia contextual** de las variables observables. Un indicador válido en un contexto puede no serlo en otro. Por ejemplo, escalas desarrolladas para grandes corporaciones pueden resultar poco pertinentes para microempresas o instituciones públicas. Lo mismo ocurre con indicadores diseñados para consumidores digitales altamente familiarizados con tecnología, que podrían no funcionar igual en poblaciones con menor experiencia digital. El investigador debe revisar si las variables observables realmente tienen sentido dentro del entorno estudiado. Esto no significa modificar arbitrariamente los constructos, sino adaptar cuidadosamente su representación empírica. Un indicador debe reflejar prácticas, percepciones o comportamientos que los sujetos puedan reconocer. Si los respondentes no entienden o no viven el fenómeno descrito, las respuestas perderán validez. En investigación administrativa, el contexto no solo condiciona la muestra; también influye en cómo se construyen y comprenden las variables observables (Henseler, 2017).

Las variables observables también deben ser coherentes con la unidad de análisis. Si el estudio se realiza en individuos, los indicadores deben capturar percepciones o comportamientos individuales. Si se realiza en empresas, los

indicadores deben representar atributos organizacionales. Un error frecuente consiste en medir constructos organizacionales mediante percepciones individuales sin justificar esa correspondencia. Por ejemplo, preguntar a empleados operativos sobre estrategia digital corporativa puede generar respuestas limitadas si no tienen acceso a esa información. Del mismo modo, utilizar respuestas individuales para representar desempeño organizacional sin agregación metodológica adecuada puede generar inconsistencias. El investigador debe definir claramente quién responderá y qué representa cada respuesta. La relación entre constructo y variable observable debe ser coherente con el nivel empírico del estudio. Esta alineación fortalece la interpretación posterior de las relaciones estructurales (Hair et al., 2021).

La medición de constructos latentes también requiere considerar el dominio conceptual. El dominio conceptual representa el conjunto de dimensiones o manifestaciones que forman parte legítima del constructo. Por ejemplo, si el aprendizaje organizacional se define como adquisición, distribución e integración de conocimiento, los indicadores deben cubrir esas áreas. Si solo se mide capacitación, el constructo queda incompleto. Del mismo modo, si la orientación al mercado incluye generación de inteligencia, difusión interna y respuesta organizacional, las variables observables deben representar esas dimensiones. Esta cobertura conceptual es necesaria para evitar mediciones parciales o sesgadas. Sin embargo, tampoco debe confundirse cobertura con acumulación excesiva. El investigador debe seleccionar suficientes indicadores para representar el constructo sin saturar el instrumento. La relación entre amplitud conceptual y parsimonia es una de las principales decisiones en el diseño de escalas. Un constructo bien representado debe capturar su esencia sin convertirse en una lista interminable de preguntas (Churchill, 1979).

La correcta construcción de variables observables también ayuda a prevenir problemas futuros de validez convergente y discriminante. Si los indicadores representan adecuadamente un mismo constructo, se espera que compartan suficiente coherencia conceptual. En cambio, si los indicadores son demasiado heterogéneos, el constructo puede perder consistencia. Del mismo modo, si los indicadores de dos constructos distintos son muy similares, puede surgir solapamiento conceptual. Por ejemplo, satisfacción y lealtad están relacionadas, pero no deben medirse con afirmaciones prácticamente idénticas. Lo mismo ocurre con confianza y seguridad percibida, o con capacidad digital y madurez digital. La prevención de estos problemas comienza en la definición conceptual y en la selección de variables observables. La estadística podrá mostrar señales posteriores, pero la primera defensa contra una mala medición es una construcción conceptual clara y diferenciada (Jarvis et al., 2003).

Otro aspecto relevante es la relación entre variables observables y escalas de medición. Las escalas tipo Likert son comunes en investigación administrativa porque permiten capturar grados de acuerdo o percepción. Sin embargo, no todos los fenómenos requieren la misma escala. Algunas variables pueden medirse mediante frecuencias, porcentajes, registros objetivos o categorías ordinales. El investigador debe seleccionar la escala más coherente con el fenómeno. Por ejemplo, intención de

uso puede medirse con acuerdo respecto a afirmaciones; frecuencia de uso tecnológico puede medirse con categorías temporales; desempeño financiero puede expresarse mediante datos cuantitativos. La escala elegida influirá en la calidad de los datos y en la interpretación del constructo. Una escala mal seleccionada puede distorsionar la representación empírica del fenómeno. La medición no es solo una cuestión estadística; también es una decisión conceptual sobre cómo capturar adecuadamente la realidad estudiada (Hair et al., 2021).

Los constructos latentes permiten además integrar fenómenos complejos dentro de sistemas estructurales más amplios. Por ejemplo, un modelo puede analizar cómo la capacidad digital influye en el aprendizaje organizacional y, posteriormente, en el desempeño innovador. En este caso, cada constructo representa una entidad abstracta vinculada con otras mediante relaciones estructurales. Sin constructos latentes, muchos fenómenos organizacionales quedarían reducidos a variables aisladas incapaces de reflejar la complejidad de la realidad administrativa. El uso de constructos permite capturar relaciones entre dimensiones abstractas, siempre que su representación empírica sea rigurosa. Por ello, la fortaleza de SEM depende en gran medida de la calidad con que los constructos latentes son definidos y medidos. La técnica no compensa debilidades conceptuales. Un modelo con constructos mal delimitados seguirá siendo débil aunque presente índices estadísticos aceptables (Henseler, 2017).

Comprender la relación entre **constructos latentes** y **variables observables** permite entender la lógica completa de SEM. El constructo representa el fenómeno teórico; la variable observable representa la evidencia empírica disponible para aproximarse a ese fenómeno. Si el constructo está mal definido, los indicadores serán ambiguos; si los indicadores son débiles, el constructo será mal representado; si ambos niveles no están alineados, las relaciones estructurales posteriores perderán sentido. Por ello, el investigador debe pensar simultáneamente en teoría y medición. Debe preguntarse qué significa el constructo, cómo se manifestará empíricamente, quién podrá responder, qué escala conviene usar y qué indicadores cubren adecuadamente el dominio conceptual. La idea central es clara: **en SEM, lo latente solo puede analizarse adecuadamente cuando lo observable ha sido cuidadosamente construido** (Hair et al., 2021).

Dimensionalidad del constructo

La dimensionalidad del constructo se refiere a la forma en que un concepto teórico se organiza internamente antes de ser medido. Un constructo puede representar una sola dimensión conceptual o puede integrar varias dimensiones relacionadas. Esta distinción es decisiva porque afecta la manera en que se redactan indicadores, se construyen escalas y se interpreta posteriormente el modelo SEM. Por ejemplo, **satisfacción** puede tratarse como un constructo unidimensional si se entiende como evaluación general de una experiencia; pero **calidad del servicio** suele requerir varias dimensiones, como confiabilidad, capacidad de respuesta, seguridad o empatía. En ciencias de la administración, muchos constructos son complejos porque

representan fenómenos organizacionales amplios: transformación digital, capacidad de innovación, aprendizaje organizacional, orientación emprendedora o sostenibilidad. Si el investigador no define su dimensionalidad, puede mezclar indicadores de distinta naturaleza y construir una escala conceptualmente confusa. Por ello, antes de evaluar cargas, AVE o confiabilidad, debe responder una pregunta básica: **¿este constructo expresa una sola idea o está compuesto por varias dimensiones diferenciables?** Esta decisión debe nacer de la teoría y no únicamente de los resultados estadísticos (Churchill, 1979).

Un **constructo unidimensional** representa una sola idea central. Sus indicadores deben apuntar hacia el mismo dominio conceptual, aunque lo hagan desde enunciados distintos. Por ejemplo, si se mide **intención de uso**, los ítems pueden preguntar si la persona planea usar una tecnología, si espera utilizarla próximamente o si tiene disposición a incorporarla en sus actividades. Aunque los enunciados varían, todos expresan una misma dimensión: la intención. En este caso, se espera coherencia entre indicadores porque todos reflejan el mismo fenómeno. La unidimensionalidad facilita la interpretación del constructo porque permite afirmar que los indicadores representan una entidad conceptual relativamente homogénea. Sin embargo, el investigador debe evitar declarar un constructo como unidimensional solo por conveniencia. Si el concepto incluye dimensiones claramente distintas, forzarlo a una sola dimensión puede empobrecer la medición. Por ejemplo, tratar **transformación digital** como una sola dimensión general puede ser insuficiente si el estudio requiere distinguir cultura digital, procesos, infraestructura y capacidades analíticas. La unidimensionalidad es adecuada cuando la teoría sostiene que el constructo tiene un núcleo conceptual compacto (Jarvis et al., 2003).

Un **constructo multidimensional** integra varias dimensiones que, en conjunto, representan un fenómeno más amplio. Cada dimensión expresa una parte del constructo general. Por ejemplo, **aprendizaje organizacional** puede incluir adquisición de conocimiento, distribución interna, interpretación compartida y aplicación del aprendizaje. **Capacidad digital** puede incluir infraestructura tecnológica, habilidades digitales, integración de datos y uso estratégico de herramientas. **Sostenibilidad empresarial** puede integrar dimensiones económicas, sociales y ambientales. En estos casos, reducir el constructo a una sola dimensión puede ocultar su complejidad. La multidimensionalidad permite representar mejor fenómenos administrativos amplios, pero también aumenta las exigencias conceptuales y metodológicas. El investigador debe explicar por qué esas dimensiones pertenecen al mismo constructo y cómo se relacionan entre sí. No basta con agrupar dimensiones porque parecen cercanas; debe existir una lógica teórica que justifique su integración. Además, cada dimensión debe estar claramente diferenciada para evitar solapamientos. Un constructo multidimensional bien diseñado permite capturar la riqueza del fenómeno sin perder coherencia interna (Hair et al., 2021).

La decisión sobre dimensionalidad debe tomarse antes de redactar indicadores. Si el investigador no sabe si el constructo es unidimensional o multidimensional, puede terminar mezclando ítems que no pertenecen al mismo dominio. Por ejemplo, si desea

medir **innovación organizacional**, puede incluir indicadores sobre nuevos productos, mejora de procesos, adopción tecnológica, cultura creativa y desempeño financiero. Aunque todos se relacionan con innovación, no necesariamente pertenecen a una sola dimensión. Algunos pueden ser resultados, otros capacidades, otros prácticas y otros condiciones. Esta mezcla puede generar una escala conceptualmente débil. Por ello, la dimensionalidad funciona como un mapa previo para organizar indicadores. Primero se define el dominio del constructo; después se decide si contiene dimensiones; luego se redactan indicadores para cada dimensión. Esta secuencia evita confusiones entre concepto, dimensión e indicador. En SEM, un error de dimensionalidad puede afectar toda la interpretación posterior del modelo. Por eso, la pregunta no debe ser cuántos ítems se necesitan, sino **qué estructura conceptual debe representar la escala** (Henseler, 2017).

La sobreamplitud dimensional ocurre cuando el investigador incluye demasiadas dimensiones dentro de un mismo constructo. Esto puede suceder con conceptos atractivos pero amplios, como desempeño organizacional, transformación digital, innovación, sostenibilidad o competitividad. Por ejemplo, si el desempeño organizacional incluye ventas, rentabilidad, productividad, satisfacción laboral, reputación, innovación, impacto social y sostenibilidad, el constructo se vuelve tan amplio que pierde claridad. La sobreamplitud dificulta la medición porque los indicadores pueden representar fenómenos distintos. También complica la interpretación: si el constructo se relaciona con otra variable, no queda claro qué parte del desempeño está siendo explicada. Para evitarlo, el investigador debe delimitar el constructo según el problema de investigación. Si el estudio busca explicar innovación, puede trabajar con **desempeño innovador**; si busca eficiencia, con **desempeño operativo**; si busca impacto ambiental, con **desempeño ambiental**. Delimitar no reduce el valor del estudio; lo hace más preciso. La dimensionalidad debe servir para clarificar, no para acumular todo dentro de una etiqueta general (Jarvis et al., 2003).

La subdimensionalidad insuficiente ocurre cuando un constructo complejo se trata como si fuera simple. Esto puede provocar una representación empobrecida del fenómeno. Por ejemplo, medir **transformación digital** únicamente con ítems sobre uso de tecnología puede ser limitado si el estudio la entiende como cambio estratégico, cultural, organizacional y operativo. Del mismo modo, medir **aprendizaje organizacional** solo con capacitación puede ser insuficiente si el constructo incluye adquisición, distribución e integración del conocimiento. Este error suele aparecer cuando el investigador desea simplificar demasiado el instrumento o cuando adopta escalas sin revisar su congruencia conceptual. En SEM, una escala breve puede ser útil, pero solo si conserva el dominio esencial del constructo. La reducción excesiva puede producir indicadores fáciles de aplicar, pero teóricamente pobres. Por ello, el investigador debe equilibrar parsimonia y cobertura conceptual. Una buena medición no requiere incluir todo, pero sí debe representar lo indispensable. La dimensionalidad ayuda a decidir qué elementos son esenciales y cuáles pueden excluirse sin alterar el significado del constructo (Churchill, 1979).

La dimensionalidad también exige distinguir entre dimensiones e **indicadores**. Una dimensión es una subparte conceptual del constructo; un indicador es una señal observable que permite medir esa dimensión o el constructo. Por ejemplo, si el constructo es **calidad del servicio**, “confiabilidad” puede ser una dimensión, mientras que “la organización cumple lo prometido” puede ser un indicador. Si el constructo es **capacidad digital**, “integración de datos” puede ser una dimensión, mientras que “la empresa integra información de distintas áreas para tomar decisiones” puede ser un indicador. Confundir dimensiones con indicadores genera problemas de diseño. Si una dimensión se trata como ítem, se pierde profundidad; si un indicador se trata como dimensión, el modelo se fragmenta innecesariamente. El investigador debe construir una jerarquía clara: constructo general, dimensiones si existen, indicadores observables para cada dimensión. Esta jerarquía permite diseñar escalas más ordenadas y facilita la interpretación del modelo. En SEM, la estructura conceptual debe anteceder a la estructura estadística (Hair et al., 2021).

Una forma útil de evaluar la dimensionalidad es preguntar si las partes del constructo son **intercambiables** o **complementarias**. En un constructo unidimensional reflectivo, los indicadores suelen ser manifestaciones intercambiables de una misma entidad. Por ejemplo, varios ítems de satisfacción pueden reflejar el mismo estado evaluativo. En cambio, en un constructo multidimensional o compuesto, las dimensiones pueden ser complementarias y no intercambiables. Por ejemplo, infraestructura digital, habilidades digitales e integración de datos no son equivalentes; cada una aporta una parte distinta de la capacidad digital. Si se elimina una dimensión complementaria, el significado del constructo puede cambiar. Esta diferencia es importante porque orienta la especificación del modelo de medición. Aunque el desarrollo técnico de reflectivos, formativos y compuestos corresponde a temas posteriores, la base conceptual está en la dimensionalidad. El investigador debe preguntarse: **si elimino esta dimensión, ¿el constructo conserva el mismo significado o pierde una parte esencial?**. La respuesta ayuda a decidir cómo debe organizarse el constructo antes de medirlo (Henseler, 2017).

La dimensionalidad teórica no debe confundirse con la dimensionalidad puramente estadística. Los análisis factoriales pueden ayudar a explorar o confirmar estructuras, pero no deben sustituir la reflexión conceptual. Si la teoría indica que un constructo tiene tres dimensiones, el investigador debe revisar empíricamente esa estructura, pero no debe decidir únicamente por conveniencia estadística. De igual manera, si un análisis sugiere más factores de los esperados, el investigador debe interpretar si esos factores tienen sentido conceptual o si son producto de mala redacción, contexto o muestra. En SEM, la estadística es una herramienta para evaluar la medición, no para inventar el constructo sin teoría. La dimensionalidad debe estar justificada desde el marco conceptual y posteriormente contrastarse con datos. Este orden protege la coherencia del modelo. Una estructura estadística aparentemente aceptable puede ser teóricamente débil si agrupa indicadores sin sentido. Por ello, la pregunta central no es solo si los indicadores cargan juntos, sino si **deben** representar una misma dimensión según la teoría (Churchill, 1979).

La dimensionalidad afecta directamente la forma de construir hipótesis. Si el constructo se trata como un todo, la hipótesis se formula sobre el constructo general. Por ejemplo: “la capacidad digital influye positivamente en el desempeño innovador”. Pero si la capacidad digital se divide en dimensiones, pueden formularse hipótesis diferenciadas: infraestructura digital, habilidades digitales e integración de datos pueden influir de manera distinta en el desempeño innovador. Esta decisión tiene consecuencias importantes. Un modelo con dimensiones separadas ofrece mayor detalle, pero también mayor complejidad. Un modelo con constructo general ofrece mayor parsimonia, pero puede ocultar efectos específicos. El investigador debe decidir qué nivel de análisis responde mejor al problema. Si el vacío de investigación se refiere al efecto global de una capacidad, puede bastar con el constructo general. Si se busca saber qué dimensión tiene mayor influencia, conviene modelar dimensiones separadas. La dimensionalidad, por tanto, no solo afecta la medición; también afecta la lógica estructural del modelo (Hair et al., 2021).

La dimensionalidad también influye en la interpretación de resultados. Si un constructo multidimensional se resume en una sola puntuación, la interpretación debe reconocer que el resultado integra varias dimensiones. Por ejemplo, si “transformación digital” se mide como constructo global, una relación positiva con desempeño innovador no indica automáticamente cuál dimensión de la transformación digital fue más relevante. En cambio, si se modelan dimensiones separadas, puede identificarse si la cultura digital, la infraestructura o la analítica de datos tienen efectos diferenciados. Esto muestra que la decisión de dimensionalidad tiene implicaciones para la contribución del estudio. Una estructura global permite una visión sintética; una estructura dimensional permite una lectura más específica. Ninguna es superior en todos los casos. La elección depende del propósito investigativo. Para estudios introductorios o modelos parsimoniosos, puede ser adecuado trabajar con constructos generales. Para investigaciones más analíticas, puede ser pertinente desagregar dimensiones. Lo importante es que la decisión sea explícita y defendible (Jarvis et al., 2003).

La dimensionalidad debe cuidar la coherencia semántica entre el nombre del constructo, sus dimensiones y sus indicadores. Si el constructo se llama “desempeño innovador”, sus dimensiones e indicadores deben referirse a resultados de innovación, no a cultura innovadora, creatividad individual o recursos tecnológicos, salvo que se justifique una estructura más amplia. Si el constructo se llama “capacidad digital”, sus dimensiones deben representar capacidades o componentes digitales, no resultados financieros derivados. La incoherencia semántica genera confusión porque el lector no sabe si el constructo representa causa, proceso o resultado. Por ello, cada nivel de la estructura debe estar alineado. El nombre del constructo debe corresponder a su definición; las dimensiones deben corresponder a esa definición; los indicadores deben representar dimensiones o manifestaciones acordes. Esta alineación fortalece la validez conceptual y prepara una evaluación estadística más sólida. Un constructo con nombre atractivo pero dimensiones incoherentes es metodológicamente débil, aunque sus indicadores parezcan bien redactados (Henseler, 2017).

La dimensionalidad también debe vincularse con el contexto de estudio. Un constructo puede tener una estructura dimensional en un contexto y otra en un contexto distinto. Por ejemplo, la transformación digital en una gran empresa industrial puede involucrar automatización avanzada, integración de sistemas, analítica de datos y rediseño de procesos; en una microempresa de servicios puede expresarse en herramientas digitales básicas, gestión de clientes en línea y uso de plataformas de pago. Esto no significa que el constructo cambie arbitrariamente, sino que su representación empírica debe ser pertinente al contexto. El investigador debe cuidar que las dimensiones elegidas sean reconocibles para la población estudiada. Una estructura muy sofisticada puede no ser adecuada para organizaciones con baja madurez tecnológica. Asimismo, una estructura demasiado básica puede ser insuficiente para empresas altamente digitalizadas. Por tanto, la dimensionalidad debe dialogar con el entorno empírico. La pertinencia contextual mejora la calidad de la medición y evita indicadores irrelevantes para los participantes (Churchill, 1979).

En términos pedagógicos, la dimensionalidad ayuda al investigador a evitar dos errores frecuentes: medir demasiado poco y medir demasiado de manera desordenada. Medir demasiado poco ocurre cuando un constructo complejo se reduce a uno o dos indicadores insuficientes. Medir demasiado de manera desordenada ocurre cuando se incluyen muchos ítems sin estructura conceptual. Ambos errores debilitan el modelo. La dimensionalidad ofrece una solución intermedia: permite identificar las partes esenciales del constructo y asignar indicadores a cada una. De esta forma, el instrumento adquiere orden. Por ejemplo, si se decide que aprendizaje organizacional tiene tres dimensiones, se pueden redactar indicadores para adquisición, distribución y aplicación del conocimiento. Así, la escala no se construye al azar, sino con una lógica interna. Esta práctica también facilita la revisión por expertos, la depuración de indicadores y la interpretación de resultados. La dimensionalidad convierte la medición en una arquitectura, no en una lista de preguntas (Hair et al., 2021).

La dimensionalidad también se relaciona con la decisión de trabajar con constructos de primer orden o constructos de orden superior. Un constructo de primer orden se mide directamente mediante indicadores. Un constructo de orden superior integra dimensiones que, a su vez, pueden funcionar como constructos de primer orden. Por ejemplo, “capacidad digital” podría modelarse como constructo de orden superior integrado por infraestructura tecnológica, habilidades digitales e integración de datos. Esta estructura puede ser útil cuando el fenómeno es amplio, pero sus dimensiones están claramente identificadas. Sin embargo, no debe aplicarse automáticamente. Los constructos de orden superior requieren una justificación conceptual sólida: debe explicarse por qué las dimensiones forman parte de una entidad común. Si las dimensiones son demasiado heterogéneas, quizá sea mejor tratarlas por separado. Si son altamente relacionadas y representan un dominio común, puede ser pertinente integrarlas. En este tema solo se introduce la lógica general; el tratamiento técnico deberá reservarse para etapas posteriores. Lo esencial es comprender que la dimensionalidad puede organizarse jerárquicamente cuando el constructo lo requiere (Henseler, 2017).

La dimensionalidad del constructo también ayuda a prevenir problemas de redundancia. Cuando dos dimensiones representan casi lo mismo, la escala puede volverse repetitiva. Por ejemplo, si una dimensión se llama "uso de tecnologías digitales" y otra "aplicación de herramientas digitales", quizá ambas estén midiendo contenidos similares. Esta redundancia puede hacer que el constructo parezca más completo, pero en realidad introduce repetición. El investigador debe revisar si cada dimensión aporta contenido nuevo. La pregunta clave es: **¿esta dimensión agrega significado o repite lo ya incluido?**. Si repite, debe fusionarse, redefinirse o eliminarse. La redundancia también puede aparecer entre indicadores dentro de una dimensión. Varios ítems muy similares pueden cansar al respondente sin aportar información adicional. Por ello, la dimensionalidad exige equilibrio: distinguir lo necesario y evitar duplicidades. Una buena estructura dimensional no es la que tiene más partes, sino la que representa mejor el dominio conceptual del constructo con claridad y economía (Jarvis et al., 2003).

Finalmente, la dimensionalidad del constructo constituye una fase intermedia entre la definición conceptual y el desarrollo de escalas. Antes de redactar indicadores, el investigador debe decidir si el constructo será unidimensional, multidimensional o jerárquico. Esta decisión afecta la forma de medir, formular hipótesis, interpretar resultados y defender el modelo. Un constructo mal dimensionado puede generar indicadores confusos, relaciones ambiguas y conclusiones débiles. En cambio, una dimensionalidad bien definida permite construir escalas coherentes y modelos SEM más interpretables. El criterio central no es la complejidad, sino la **correspondencia entre teoría, fenómeno y medición**. Si el fenómeno es simple, no debe complicarse artificialmente; si es complejo, no debe reducirse en exceso. El investigador debe buscar una estructura suficiente, clara y defendible. Este tema prepara el desarrollo posterior de escalas y la especificación conceptual antes de medir. La idea clave es que **medir bien exige primero dimensionar bien** (Hair et al., 2021).

Desarrollo inicial de escala

El **desarrollo inicial de escalas** es el proceso mediante el cual un constructo definido conceptualmente se transforma en un conjunto organizado de **indicadores observables** (Mejía-Trejo, 2023). Esta etapa es decisiva porque una escala no debe nacer de ocurrencias, intuiciones o frases atractivas, sino de una correspondencia clara entre **teoría, constructo, dimensiones e ítems**. En SEM, los indicadores serán la base del modelo de medición; por ello, si la escala nace débil, el análisis posterior también será débil. Antes de redactar preguntas, el investigador debe confirmar qué significa el constructo, qué dominio conceptual cubre, qué dimensiones lo integran y qué tipo de evidencia observable permitirá representarlo. Por ejemplo, si se desea medir **aprendizaje organizacional**, la escala no debería limitarse a capacitación, sino reflejar procesos como adquisición, distribución, interpretación y aplicación del conocimiento, siempre que esas dimensiones hayan sido definidas previamente. Una escala rigurosa no mide todo lo relacionado con el tema, sino aquello que pertenece al

constructo. Por ello, el desarrollo inicial de escalas exige **coherencia teórica, claridad semántica, pertinencia contextual y correspondencia empírica** desde el diseño (Churchill, 1979).

El primer paso consiste en delimitar el dominio conceptual de la escala. El dominio conceptual indica qué contenido pertenece legítimamente al constructo y qué contenido debe quedar fuera. Por ejemplo, si el constructo es **desempeño innovador**, la escala debe centrarse en resultados de innovación, como introducción de productos, mejora de procesos o generación de soluciones nuevas, y no en recursos tecnológicos, creatividad individual o cultura innovadora, salvo que esos elementos hayan sido definidos como parte del constructo. Si el constructo es **capacidad digital**, deben precisarse sus posibles componentes: infraestructura tecnológica, habilidades digitales, integración de datos, uso estratégico de herramientas o procesos digitales. Esta delimitación evita que los ítems mezclen antecedentes, procesos, resultados y condiciones contextuales. Una escala puede parecer más completa por incluir muchos elementos, pero si esos elementos pertenecen a constructos distintos, la medición será confusa. El dominio conceptual funciona como frontera metodológica: permite decidir qué indicadores son pertinentes, cuáles deben reformularse y cuáles deben excluirse. Sin esa frontera, la escala se convierte en una lista heterogénea de afirmaciones difíciles de interpretar (Jarvis et al., 2003).

El segundo paso es organizar los indicadores de acuerdo con la dimensionalidad del constructo. Si el constructo es unidimensional, todos los ítems deben representar la misma idea central desde diferentes manifestaciones. Por ejemplo, una escala de **intención de uso** puede incluir afirmaciones sobre disposición, plan futuro y probabilidad de uso, siempre que todas apunten al mismo dominio. Si el constructo es multidimensional, cada dimensión debe contar con indicadores propios. Por ejemplo, una escala de **capacidad digital organizacional** puede incluir ítems sobre infraestructura tecnológica, competencias digitales, integración de datos y uso estratégico de herramientas. Esta organización permite revisar si alguna dimensión está sobrerrepresentada o subrepresentada. También evita que el instrumento crezca sin estructura. Un problema frecuente es redactar muchos ítems para una dimensión visible y pocos para dimensiones igualmente importantes. El desarrollo inicial de escalas debe buscar cobertura suficiente y balanceada. No se trata de redactar el mayor número de ítems posible, sino de asegurar que cada indicador tenga una función clara dentro de la medición y contribuya a representar el dominio del constructo (Hair et al., 2021).

La redacción de ítems debe seguir un principio fundamental: cada indicador debe expresar una sola idea. Los ítems con doble contenido generan ambigüedad porque el participante puede estar de acuerdo con una parte y en desacuerdo con otra. Por ejemplo, la afirmación “la empresa usa tecnologías digitales y capacita al personal para innovar” mezcla dos contenidos diferentes: uso tecnológico y capacitación. Si el respondente percibe que la empresa sí usa tecnologías, pero no capacita al personal, su respuesta no será interpretable. Un diseño más adecuado separaría ambas ideas en ítems distintos. La claridad del indicador también exige evitar frases excesivamente

largas, tecnicismos innecesarios, negaciones dobles y términos absolutos como “siempre”, “nunca” o “completamente”, salvo que exista una razón metodológica para utilizarlos. En investigación administrativa, los participantes pueden provenir de empresas, instituciones, consumidores, estudiantes o empleados con distintos niveles de familiaridad conceptual. Por ello, un ítem riguroso no es el más sofisticado, sino el que traduce el constructo en una afirmación **clara, específica, comprensible y respondible** (Churchill, 1979).

El desarrollo inicial de escalas exige cuidar la pertinencia del informante. No todas las personas están en condiciones de responder sobre todos los constructos. Un directivo puede evaluar estrategia, capacidades organizacionales, desempeño o innovación; un empleado operativo puede responder mejor sobre clima laboral, procesos cotidianos o experiencia de trabajo; un cliente puede evaluar satisfacción, confianza, lealtad o calidad percibida. Si el informante no tiene conocimiento suficiente, la escala producirá datos débiles. Por ejemplo, preguntar a consumidores sobre capacidades internas de innovación de una empresa puede ser inadecuado. De igual manera, preguntar a empleados sin acceso estratégico sobre inversión digital corporativa puede generar respuestas especulativas. Por ello, antes de aplicar una escala, el investigador debe responder: **¿quién puede contestar válidamente este ítem?, ¿la persona tiene experiencia directa con el fenómeno?, ¿la unidad de análisis coincide con el informante?, ¿la respuesta representa una percepción individual o un atributo organizacional?**. Esta revisión evita errores de correspondencia entre constructo, indicador y fuente de datos (Jarvis et al., 2003).

La escala de respuesta debe corresponder a la naturaleza del constructo. Las escalas tipo Likert son frecuentes cuando se miden percepciones, actitudes o grados de acuerdo. Sin embargo, no todos los fenómenos deben capturarse mediante acuerdo/desacuerdo. Algunos requieren frecuencia, intensidad, nivel de implementación, grado de uso, porcentaje, conteo o dato objetivo. Por ejemplo, la **intención de uso** puede medirse mediante acuerdo con afirmaciones; la **frecuencia de uso tecnológico** puede requerir categorías temporales; el **tamaño de empresa** puede medirse con número de empleados; y el **desempeño financiero** puede requerir indicadores objetivos o rangos cuantitativos. Elegir una escala incorrecta distorsiona la representación empírica del constructo. Además, cuando se combinan diferentes escalas dentro de un instrumento, el investigador debe justificar su uso y cuidar la claridad para el respondente. La escala de respuesta no es un detalle operativo, sino una decisión conceptual sobre cómo se capturará el fenómeno. Una escala adecuada permite que la variable observable exprese con mayor fidelidad el constructo que se desea estudiar (Hair et al., 2021).

El investigador debe procurar que los ítems mantengan coherencia semántica interna. Esto significa que todos los indicadores asociados a un constructo deben apuntar al mismo dominio conceptual. Si una escala mide **satisfacción**, sus ítems no deben mezclarse con lealtad, recomendación, confianza o intención de recompra, salvo que tales dimensiones hayan sido justificadas dentro del constructo. Si se mide **aprendizaje organizacional**, los ítems deben representar procesos de aprendizaje y

no resultados de desempeño. Esta coherencia ayuda a prevenir confusiones entre constructos. También facilita que, más adelante, el modelo de medición pueda evaluarse con mayor claridad. Una escala puede fallar no porque cada ítem sea incorrecto de manera aislada, sino porque el conjunto no representa una misma entidad conceptual. Por ello, el desarrollo inicial de escalas exige revisar el instrumento como sistema, no solo como lista de frases. La pregunta clave es: **¿todos estos ítems representan el mismo constructo o estoy mezclando fenómenos diferentes?** La coherencia semántica es el puente entre definición conceptual y medición empírica (Henseler, 2017).

También debe evitarse el sesgo de deseabilidad social, especialmente cuando se miden constructos relacionados con ética, sostenibilidad, responsabilidad social, innovación, liderazgo, inclusión o desempeño. Los participantes pueden sentirse inclinados a responder de manera favorable si el ítem suena moralmente deseable. Por ejemplo, “mi organización siempre actúa con responsabilidad social” puede inducir respuestas positivas poco diferenciadas. Para reducir este riesgo, conviene redactar ítems más específicos y observables, como “la organización incorpora criterios sociales en la toma de decisiones” o “se consideran impactos ambientales al planear proyectos”. La neutralidad del ítem mejora la calidad de la respuesta. Esto no elimina todos los sesgos, pero reduce la presión a contestar de forma idealizada. El desarrollo inicial de escalas debe buscar indicadores que permitan variación real entre casos. Si todos los participantes tienden a contestar positivamente por presión social, la escala pierde capacidad analítica. Una buena redacción permite respuestas sinceras diferenciadas y útiles para representar el constructo (Churchill, 1979).

El desarrollo inicial de escalas requiere revisar la adaptación contextual de los ítems. Una escala creada para grandes corporaciones puede no funcionar igual en pymes, universidades, instituciones públicas, emprendimientos o comunidades profesionales. Un ítem sobre sistemas avanzados de analítica predictiva puede ser pertinente para empresas altamente digitalizadas, pero no para microempresas con bajo nivel tecnológico. Del mismo modo, una escala de innovación diseñada para manufactura puede necesitar ajustes para servicios, educación o gobierno. Adaptar no significa alterar sin criterio, sino conservar el significado conceptual del constructo mientras se ajusta el lenguaje, los ejemplos y la pertinencia contextual. El investigador debe preguntarse si los participantes reconocerán las situaciones descritas por los ítems. Si los indicadores no corresponden a la realidad del contexto, las respuestas serán poco útiles. La validez de una escala depende de que sus ítems sean comprensibles, relevantes y aplicables a la población estudiada. La escala debe hablar el lenguaje del contexto sin perder rigor conceptual (Jarvis et al., 2003).

Una escala inicial también debe evitar la redundancia innecesaria. Es común que, al intentar asegurar la medición, el investigador redacte muchos ítems muy parecidos. Por ejemplo, “la empresa innova constantemente”, “la empresa introduce innovaciones de manera continua” y “la empresa desarrolla innovaciones con frecuencia” pueden capturar casi la misma idea. Aunque cierta cercanía entre indicadores puede ser esperada en constructos reflectivos, la repetición excesiva no

añade información sustantiva y puede cansar al respondente. La redundancia también puede ocultar falta de cobertura: una dimensión aparece muy medida, mientras otras quedan poco representadas. Por ello, el desarrollo de escalas debe equilibrar **suficiencia y economía**. Una escala inicial puede incluir más ítems de los que finalmente se conservarán, pero cada uno debe aportar algún matiz relevante. El criterio no debe ser "cuántos ítems tengo", sino **qué parte del constructo representa cada ítem**. La economía de medición favorece instrumentos más claros y datos de mejor calidad (Hair et al., 2021).

La escala debe diseñarse considerando si el constructo será tratado como reflectivo, formativo o compuesto. En los constructos reflectivos, los ítems suelen ser manifestaciones del mismo fenómeno y se espera que guarden coherencia conceptual entre sí. Por ejemplo, en una escala de **satisfacción**, varios ítems pueden reflejar la evaluación general de una experiencia. En los constructos formativos o compuestos, los indicadores pueden representar componentes diferentes que integran el constructo. Por ejemplo, una **capacidad digital organizacional** puede requerir indicadores sobre infraestructura, habilidades, procesos e integración de datos, los cuales no son necesariamente intercambiables. Aunque el tratamiento técnico se desarrollará después, desde el diseño inicial debe existir una decisión conceptual. El investigador debe preguntarse: **¿los indicadores reflejan el constructo o lo forman?**. Esta pregunta evita errores de especificación que posteriormente podrían afectar la interpretación del modelo (Henseler, 2017).

Una práctica recomendable es elaborar una matriz de operacionalización antes de aplicar la escala. Esta matriz puede incluir: constructo, definición conceptual, dimensiones, indicadores, escala de respuesta y fuente teórica. Su utilidad es verificar que cada ítem esté vinculado con una parte del constructo y que no existan indicadores sueltos. Por ejemplo, si se trabaja con **capacidad digital**, la matriz permite revisar si existen ítems para infraestructura, habilidades, integración de datos y uso estratégico. También ayuda a detectar dimensiones sin indicadores o ítems que no corresponden a ninguna dimensión. Esta herramienta es especialmente útil para estudiantes, porque convierte el desarrollo de escalas en un proceso ordenado y verificable. La matriz no sustituye la validación estadística, pero mejora la calidad conceptual del instrumento. En SEM, la claridad de la operacionalización facilita después la evaluación del modelo de medición. Una escala bien organizada desde la matriz tiene más posibilidades de producir resultados interpretables (Churchill, 1979).

El desarrollo inicial de escalas debe incluir una revisión de validez de contenido. Esta validez se refiere a si los indicadores cubren adecuadamente el dominio conceptual del constructo. Aunque la evaluación formal puede involucrar jueces expertos, desde esta etapa el investigador debe preguntarse si los ítems representan lo esencial del constructo. Una escala con validez de contenido débil puede omitir dimensiones importantes o incluir indicadores ajenos al fenómeno. Por ejemplo, una escala de **aprendizaje organizacional** que solo pregunte por capacitación puede omitir intercambio de conocimiento, memoria organizacional o aplicación práctica. Una escala de **sostenibilidad** que solo incluya aspectos

ambientales puede dejar fuera dimensiones sociales o económicas, si el constructo fue definido desde una lógica integral. La validez de contenido es previa a los índices estadísticos. Un instrumento puede mostrar resultados numéricos aceptables y aun así medir un constructo incompleto. Por ello, revisar contenido antes de aplicar la escala es una condición indispensable de rigor (Jarvis et al., 2003).

También conviene realizar una revisión de comprensión antes de aplicar el instrumento a gran escala. Esta revisión puede consistir en lectura por colegas, evaluación de expertos, prueba piloto o entrevistas cognitivas con algunos participantes. El objetivo es detectar ítems confusos, ambiguos, demasiado largos, redundantes o poco pertinentes. Muchas veces el investigador entiende perfectamente un ítem porque conoce la teoría, pero el participante puede interpretarlo de otra manera. La prueba de comprensión ayuda a identificar estos problemas antes de recolectar datos definitivos. En investigaciones administrativas, esta fase es especialmente útil cuando se trabaja con conceptos técnicos como digitalización, innovación, capacidades dinámicas, sostenibilidad o modelos de negocio. Si los participantes no comprenden los ítems, la calidad de los datos se verá afectada. La revisión previa permite ajustar lenguaje, ejemplos, longitud y estructura del cuestionario. Así, el desarrollo inicial de escalas no termina con la redacción de ítems; requiere verificar que esos ítems funcionen en la población objetivo (Churchill, 1979).

El orden de los ítems dentro del cuestionario también puede influir en la calidad de las respuestas. Aunque este tema pertenece al diseño del instrumento, conviene señalar que los ítems deben organizarse de manera lógica, evitando saltos bruscos entre temas y reduciendo la fatiga del respondente. Si el cuestionario inicia con preguntas muy técnicas o sensibles, puede generar rechazo o respuestas poco cuidadosas. Si agrupa demasiados ítems similares, puede inducir respuestas automáticas. Una escala debe integrarse dentro de un instrumento claro, con instrucciones precisas y flujo comprensible. Además, cuando se miden varios constructos en una misma encuesta, conviene cuidar que los ítems no induzcan respuestas por asociación artificial. La organización del cuestionario no es un detalle menor: puede afectar la calidad de las variables observables. En SEM, donde muchas relaciones se estiman a partir de datos autoinformados, el diseño del instrumento debe reducir fuentes innecesarias de error. La escala debe ser conceptualmente sólida y operativamente aplicable (Hair et al., 2021).

El investigador debe evitar que la escala confunda antecedentes, procesos y resultados dentro de un mismo constructo. Este error es común cuando se trabaja con fenómenos amplios, como innovación, transformación digital, sostenibilidad o desempeño. Por ejemplo, una escala de **desempeño innovador** no debería mezclar ítems sobre recursos disponibles, cultura innovadora y resultados obtenidos, porque esos elementos podrían pertenecer a constructos distintos. Los recursos pueden ser antecedentes, la cultura puede ser condición o antecedente, y los resultados pueden ser la consecuencia. Si todo se mezcla en una misma escala, el constructo pierde precisión. Esta separación es fundamental para SEM, porque el modelo estructural depende de distinguir qué variable explica y qué variable es explicada. La escala debe

representar el constructo definido, no todo el ecosistema del fenómeno. Por ello, antes de cerrar el instrumento, el investigador debe revisar si cada ítem mide realmente el constructo o si pertenece a otra parte del modelo (Jarvis et al., 2003).

El desarrollo inicial de escalas debe considerar el número razonable de ítems por constructo o dimensión. Una escala demasiado breve puede no cubrir adecuadamente el dominio conceptual; una escala demasiado extensa puede generar cansancio y respuestas automáticas. Para constructos unidimensionales, suele ser recomendable contar con varios indicadores que representen el núcleo conceptual; para constructos multidimensionales, cada dimensión debe contar con suficiente representación. Sin embargo, no existe un número universal válido para todos los casos. La decisión depende de la complejidad del constructo, del tipo de estudio, de la población y de la extensión total del cuestionario. Lo importante es que cada ítem aporte información. Una escala inicial puede ser más amplia para permitir depuración posterior, pero no debe incluir indicadores redundantes o irrelevantes. En investigación aplicada, el equilibrio entre **cobertura conceptual** y **carga para el respondente** es clave. Una escala defendible no es la más larga, sino la que representa adecuadamente el constructo con economía y claridad (Hair et al., 2021).

La escala también debe cuidar la dirección de los ítems. Algunos instrumentos combinan ítems positivos y negativos con la intención de reducir respuestas automáticas; sin embargo, los ítems negativos pueden generar confusión si no están redactados con cuidado. En poblaciones con distintos niveles educativos o con baja familiaridad con encuestas, las negaciones pueden inducir errores de interpretación. Por ejemplo, un ítem como “la organización no carece de procesos de innovación” puede resultar innecesariamente confuso. Si se usan ítems invertidos, deben ser simples, claros y coherentes. En muchos casos, es preferible reducir ambigüedad mediante redacción directa, instrucciones claras y diseño ordenado del cuestionario. La dirección de los ítems afecta la calidad de la variable observable. Un indicador mal orientado puede introducir ruido y afectar la medición del constructo. Por ello, la claridad debe tener prioridad sobre la sofisticación aparente del instrumento (Churchill, 1979).

El desarrollo inicial de escalas requiere cuidar la equivalencia conceptual cuando se adaptan ítems de otros estudios. Adaptar una escala no significa traducir palabras de manera literal; implica asegurar que el ítem conserve el mismo significado en el nuevo contexto. Por ejemplo, una escala desarrollada en inglés para empresas tecnológicas puede requerir ajustes si se aplica en pymes latinoamericanas, organizaciones públicas o instituciones educativas. Algunos términos pueden no tener equivalentes directos o pueden interpretarse de forma distinta. La equivalencia conceptual exige revisar lenguaje, contexto, sector, población y unidad de análisis. Si se altera demasiado el ítem, puede cambiar el constructo; si se traduce literalmente sin adaptación, puede perder sentido para los participantes. Por ello, la adaptación debe equilibrar fidelidad conceptual y pertinencia contextual. Esta revisión fortalece la calidad de la escala y evita que el investigador aplique instrumentos sin considerar las condiciones reales del campo de estudio (Henseler, 2017).

También es importante revisar la sensibilidad de la escala. Una escala debe permitir distinguir diferencias entre casos. Si todos los participantes tienden a responder lo mismo, el indicador tendrá poca utilidad analítica. Esto puede ocurrir cuando los ítems son demasiado obvios, moralmente deseables, excesivamente generales o poco relacionados con la experiencia real del respondente. Por ejemplo, "la innovación es importante para la empresa" probablemente recibirá respuestas altas en casi todos los casos, pero no necesariamente discrimina niveles reales de innovación. Un ítem más útil podría preguntar por prácticas concretas, frecuencia de introducción de mejoras o aplicación de nuevas soluciones. La sensibilidad no significa hacer preguntas difíciles, sino diseñar indicadores capaces de capturar variación. **En SEM, la falta de variabilidad puede debilitar la estimación de relaciones estructurale**s. Por ello, una escala inicial debe incluir ítems que permitan observar diferencias reales entre individuos, equipos u organizaciones (Jarvis et al., 2003).

El investigador debe considerar también la longitud total del cuestionario. Una escala puede estar bien diseñada de manera individual, pero el instrumento completo puede resultar excesivo si incluye muchos constructos, dimensiones e ítems. La fatiga del respondente puede reducir la calidad de las respuestas, aumentar respuestas automáticas o provocar abandono. Por ello, el desarrollo inicial de escalas debe dialogar con la arquitectura completa del modelo. Si el modelo tiene muchos constructos, quizá sea necesario usar escalas más breves, sin sacrificar validez de contenido. Si el estudio se concentra en pocos constructos centrales, puede permitirse mayor profundidad en cada escala. La longitud debe responder al propósito del estudio y a las características de la población. En investigaciones con directivos o profesionales con poco tiempo, la economía del instrumento es especialmente importante. La escala no debe diseñarse de manera aislada; debe integrarse en un cuestionario viable, claro y respetuoso del tiempo del participante (Hair et al., 2021).

La escala inicial debe documentar la fuente de los indicadores. Algunos ítems pueden provenir de escalas previas, otros pueden adaptarse y otros pueden ser desarrollados por el investigador. En todos los casos, conviene registrar su origen y justificación. Esta trazabilidad permite defender el instrumento y facilita la revisión académica. Si un ítem se adapta, debe explicarse qué cambio se hizo y por qué. Si se desarrolla un ítem nuevo, debe justificarse con base en la definición conceptual del constructo. Esta documentación evita que la escala parezca improvisada. Además, permite que otros investigadores comprendan cómo se construyó la medición. En un modelo SEM, la trazabilidad de los indicadores fortalece la confianza en el análisis posterior. La escala no debe ser una caja negra; debe mostrar cómo cada indicador se relaciona con la teoría, con el constructo y con el contexto del estudio (Churchill, 1979).

Finalmente, el desarrollo inicial de escalas es una fase de traducción entre teoría y datos. El investigador parte de un constructo, define su dominio, identifica dimensiones, redacta indicadores, selecciona una escala de respuesta, revisa pertinencia contextual y prepara una matriz de operacionalización. Esta secuencia evita que la medición sea improvisada. En SEM, la escala no es un accesorio del modelo; es la base empírica que permitirá estimar constructos y relaciones. Un modelo

estructural solo será interpretable si sus constructos fueron medidos con indicadores claros, pertinentes y coherentes. Por ello, antes de hablar de resultados, el investigador debe asegurar que la escala representa el fenómeno que afirma estudiar. Este tema prepara el avance hacia la especificación conceptual antes de medir, donde se revisará cómo las decisiones sobre constructos, dimensiones e indicadores deben alinearse antes de ejecutar cualquier análisis estadístico. La idea central es simple: **sin escala bien diseñada, no hay modelo SEM defendible** (Henseler, 2017).

Especificación conceptual antes de medir

La **especificación conceptual antes de medir** es la fase que asegura que el constructo, sus dimensiones y sus indicadores estén alineados antes de aplicar cualquier cuestionario o ejecutar un modelo SEM. Después de definir conceptos, variables, constructos latentes, variables observables, dimensionalidad y escalas iniciales, el investigador debe detenerse a revisar si todo el sistema de medición tiene coherencia interna. Esta etapa es indispensable porque una escala puede parecer bien redactada, pero estar midiendo algo distinto de lo que el constructo declara representar. Por ello, la pregunta central es: **¿lo que voy a medir corresponde exactamente con el constructo que digo estudiar?**. Si la respuesta no es clara, el modelo nacerá débil, aunque después los resultados estadísticos parezcan aceptables. La especificación conceptual protege la validez del estudio porque conecta teoría, definición, dimensiones, indicadores, escala de respuesta y unidad de análisis dentro de una misma lógica metodológica (Churchill, 1979).

El primer paso consiste en verificar la alineación entre definición conceptual y dominio de medición. Un constructo no puede medirse correctamente si su definición es ambigua, demasiado amplia o inestable. Por ejemplo, si se define **transformación digital** como cambio estratégico organizacional, los indicadores no deberían limitarse al uso básico de herramientas digitales. Si se define **desempeño innovador** como resultados derivados de nuevos productos, procesos o servicios, los ítems no deberían medir cultura creativa, recursos tecnológicos o intención de innovar, porque esos elementos podrían ser antecedentes y no resultados. Esta revisión evita mezclar causas, procesos y consecuencias dentro de una misma escala. La especificación conceptual exige separar con claridad qué pertenece al constructo y qué pertenece a otras partes del modelo. Un error en esta etapa puede provocar que el investigador mida una cosa, interprete otra y relacione ambas con un tercer fenómeno. Por ello, el constructo debe tener una frontera conceptual clara antes de pasar a la medición empírica (Jarvis et al., 2003).

El segundo paso consiste en revisar la coherencia entre constructo y dimensionalidad. Si el constructo fue definido como unidimensional, sus indicadores deben apuntar a una misma idea central. Si fue definido como multidimensional, cada dimensión debe estar claramente identificada y contar con indicadores pertinentes. Por ejemplo, una escala de **aprendizaje organizacional** puede incluir adquisición, distribución e integración del conocimiento; pero si esas dimensiones fueron declaradas, deben estar representadas de manera balanceada. No sería coherente

incluir cinco ítems sobre capacitación y ninguno sobre aplicación del conocimiento. La dimensionalidad debe funcionar como puente entre teoría e indicadores. Si las dimensiones no se respetan, la escala pierde estructura. Si se agregan dimensiones no justificadas, el constructo se vuelve difuso. La especificación conceptual permite revisar si la escala conserva la arquitectura interna del constructo antes de aplicar el instrumento. En SEM, la dimensionalidad no es solo un tema estadístico; es una decisión teórica que condiciona la forma en que el constructo será interpretado (Hair et al., 2021).

El tercer paso es decidir si el constructo será tratado como reflectivo, formativo o compuesto. Esta decisión debe tomarse antes de medir, no después de revisar resultados. En un constructo **reflectivo**, los indicadores son manifestaciones del constructo; por ejemplo, distintos ítems pueden reflejar satisfacción, confianza o compromiso. En un constructo **formativo**, los indicadores contribuyen a formar el constructo; por ejemplo, infraestructura tecnológica, habilidades digitales, integración de datos y uso estratégico pueden formar una capacidad digital. En un constructo **compuesto**, los indicadores se integran como componentes de una entidad construida para el análisis. La pregunta clave es: **¿los indicadores son efectos del constructo o partes que lo constituyen?**. Si esta pregunta se responde mal, el modelo puede quedar mal especificado desde su origen. La especificación incorrecta puede afectar la selección de indicadores, la interpretación de resultados y la evaluación posterior del modelo de medición. Por ello, la lógica conceptual debe preceder a la decisión técnica (Henseler, 2017).

La especificación conceptual también exige revisar la dirección de significado entre constructo e indicadores. Si el constructo cambia y se espera que todos los indicadores cambien en la misma dirección, probablemente se trata de una lógica reflectiva. Por ejemplo, si aumenta la satisfacción, deberían aumentar las respuestas positivas en distintos ítems de satisfacción. En cambio, si cada indicador aporta una parte distinta del constructo, la lógica puede ser formativa o compuesta. Por ejemplo, una capacidad digital no necesariamente aumenta de manera uniforme en infraestructura, habilidades, procesos y analítica; cada componente puede aportar algo diferente. Esta diferencia no debe resolverse por costumbre ni por facilidad de uso del software. Debe resolverse por la naturaleza teórica del constructo. Una mala especificación puede llevar a eliminar indicadores que conceptualmente son necesarios o a conservar ítems redundantes que no agregan valor. Por ello, antes de medir, el investigador debe justificar cómo se relacionan los indicadores con el constructo (Jarvis et al., 2003).

Otro aspecto esencial es comprobar la unidad de análisis. Todo constructo debe corresponder al nivel donde se recolectarán e interpretarán los datos. Si el constructo es individual, los indicadores deben captar percepciones, actitudes o conductas individuales. Si el constructo es organizacional, los indicadores deben representar prácticas, capacidades o resultados de la organización. Por ejemplo, **intención de uso** suele medirse a nivel individual; **capacidad de innovación organizacional** requiere información sobre la empresa o institución. Un error común consiste en formular

constructos organizacionales y medirlos con respuestas individuales sin justificar que el informante representa adecuadamente a la organización. Esta confusión puede debilitar el modelo porque mezcla niveles de análisis. La especificación conceptual obliga a responder: **¿quién responde?, ¿qué representa su respuesta?, ¿el dato corresponde al nivel del constructo?, ¿las conclusiones se harán sobre individuos, organizaciones o grupos?**. Sin esta correspondencia, la medición puede ser técnicamente ordenada, pero conceptualmente inválida (Hair et al., 2021).

La especificación conceptual debe revisar también la pertinencia del informante. No todos los sujetos pueden responder sobre todos los constructos. Un directivo puede responder sobre estrategia, capacidades, innovación o desempeño organizacional; un empleado puede responder sobre clima, procesos o experiencia laboral; un cliente puede responder sobre satisfacción, confianza o lealtad. Si el informante no tiene conocimiento suficiente, la variable observable pierde calidad. Por ejemplo, no sería adecuado preguntar a un cliente sobre capacidades internas de innovación de una empresa. Tampoco sería ideal preguntar a un empleado sin acceso estratégico sobre inversión tecnológica institucional. Esta revisión permite evitar respuestas especulativas. La calidad de una escala no depende solo de la redacción del ítem, sino de que la persona encuestada tenga condiciones para responderlo. Por ello, antes de medir, debe verificarse que cada indicador sea **respondible**, es decir, que pueda ser contestado por el informante con conocimiento, experiencia o percepción pertinente (Churchill, 1979).

La especificación conceptual también debe evitar la **confusión entre antecedentes, dimensiones e indicadores**. En muchos modelos, el investigador mezcla elementos que pertenecen a niveles distintos. Por ejemplo, si se estudia **desempeño innovador**, no debe mezclarse en la misma escala la cultura innovadora, la inversión tecnológica y los resultados de innovación, porque podrían ocupar posiciones diferentes dentro del modelo. La cultura puede ser antecedente, la inversión puede ser recurso y el desempeño innovador puede ser consecuencia. Si todo se mide como un solo constructo, se pierde claridad estructural. Del mismo modo, una dimensión no debe confundirse con un indicador. “Integración de datos” puede ser una dimensión de capacidad digital; un indicador sería una afirmación observable sobre cómo la organización integra información entre áreas. Esta separación permite construir escalas más ordenadas y modelos más interpretables. La especificación conceptual exige que cada elemento tenga su lugar: **constructo, dimensión, indicador, antecedente o resultado** (Jarvis et al., 2003).

Otro punto importante es la validez de contenido preliminar. Antes de aplicar el instrumento, el investigador debe revisar si los indicadores cubren adecuadamente el dominio del constructo. Una escala puede estar bien redactada, pero ser incompleta. Por ejemplo, si aprendizaje organizacional incluye adquisición, distribución e integración de conocimiento, una escala centrada solo en capacitación no cubre todo el constructo. Si sostenibilidad empresarial se define desde una lógica económica, social y ambiental, una escala exclusivamente ambiental sería parcial. La validez de contenido no depende primero de cálculos estadísticos, sino de la correspondencia

entre definición e indicadores. Por ello, conviene revisar la escala mediante una matriz donde se observe qué indicador representa cada dimensión. Esta revisión ayuda a detectar omisiones, redundancias o indicadores ajenos. En SEM, un constructo incompleto puede generar resultados aparentemente consistentes, pero conceptualmente insuficientes. La medición debe cubrir lo esencial del constructo sin mezclar contenidos externos (Churchill, 1979).

La especificación conceptual debe incorporar una revisión de redundancia conceptual. Dos indicadores pueden decir casi lo mismo con palabras distintas. Aunque cierta cercanía es esperable en constructos reflectivos, la repetición excesiva no aporta información y puede cansar al respondente. Por ejemplo, “la empresa innova constantemente”, “la empresa innova de manera continua” y “la empresa desarrolla innovaciones frecuentemente” podrían ser demasiado similares. La redundancia también puede aparecer entre constructos: capacidad digital, madurez digital y transformación digital pueden solaparse si no se delimitan. Esta revisión ayuda a prevenir problemas posteriores de colinealidad o falta de validez discriminante, pero sin entrar todavía a su evaluación técnica. La pregunta central es: **¿este indicador o constructo aporta contenido nuevo o repite lo ya medido?**. Si repite, debe eliminarse, fusionarse o reformularse. La especificación conceptual busca equilibrio entre cobertura suficiente y economía de medición (Hair et al., 2021).

También debe revisarse la claridad semántica de los indicadores. Un ítem debe ser comprensible para la población objetivo, usar lenguaje adecuado y evitar ambigüedades. Expresiones demasiado técnicas pueden ser problemáticas para pymes, estudiantes, consumidores o empleados sin formación especializada. Por ejemplo, un ítem sobre “analítica predictiva integrada al ecosistema digital” puede ser pertinente para empresas tecnológicas avanzadas, pero no para microempresas. La claridad semántica implica que el participante entienda lo que se le pregunta y pueda responder de manera diferenciada. También exige evitar ítems con doble contenido, negaciones innecesarias o términos absolutos. Un indicador confuso no representa adecuadamente el constructo; introduce ruido en la medición. Por ello, la especificación conceptual debe revisar cada ítem desde la perspectiva del respondente, no solo desde la perspectiva del investigador. Una escala académicamente elegante puede fallar si no es entendible para quienes la contestan (Churchill, 1979).

La especificación conceptual debe asegurar la pertinencia contextual de los indicadores. Una escala desarrollada en un contexto puede no funcionar igual en otro. Por ejemplo, indicadores de transformación digital diseñados para corporaciones multinacionales pueden no ser adecuados para pymes locales. Indicadores de innovación en manufactura pueden requerir ajustes si se aplican en servicios, educación o gobierno. La adaptación contextual no significa cambiar arbitrariamente el constructo, sino hacer que sus indicadores sean comprensibles y pertinentes sin perder el significado teórico. El investigador debe preguntarse: **¿este indicador describe una práctica reconocible en el contexto estudiado?, ¿el lenguaje corresponde a la realidad de los participantes?, ¿el ítem mantiene el sentido**

conceptual original?. Si el indicador no tiene relación con la experiencia de los sujetos, las respuestas serán débiles. En administración, el contexto condiciona no solo la muestra, sino también la forma en que los constructos se manifiestan empíricamente (Henseler, 2017).

La especificación conceptual también debe considerar la escala de respuesta. No todos los indicadores deben medirse con la misma escala. Las escalas tipo Likert son útiles para percepciones, actitudes y grados de acuerdo; pero algunos indicadores pueden requerir frecuencia, intensidad, nivel de implementación, conteo o datos objetivos. Por ejemplo, la intención de uso puede medirse con acuerdo; la frecuencia de uso tecnológico con categorías temporales; el tamaño de empresa con número de empleados; y el desempeño financiero con rangos o datos contables. La escala de respuesta debe ser coherente con la naturaleza del indicador. Si se usa una escala inadecuada, el dato puede distorsionar el constructo. Además, la escala debe ser comprensible y consistente para el participante. La especificación conceptual obliga a revisar no solo qué se pregunta, sino **cómo se captura la respuesta**. Esta decisión es parte de la medición, no un detalle de formato (Hair et al., 2021).

Una práctica recomendable es construir una **matriz de especificación conceptual**. Esta matriz puede incluir: constructo, definición conceptual, dimensión, indicador, tipo de indicador, escala de respuesta, unidad de análisis, informante esperado y justificación teórica. Su función es verificar que cada indicador tenga una razón de existir. Si un ítem no puede vincularse con una dimensión o definición, debe revisarse. Si una dimensión no tiene indicadores, debe completarse o eliminarse. Si un indicador pertenece a otro constructo, debe reubicarse. Esta matriz permite visualizar la coherencia del instrumento antes de aplicarlo. Además, facilita la revisión por asesores, jueces expertos o comités académicos. Para estudiantes, es una herramienta especialmente valiosa porque evita que el cuestionario se construya por acumulación de preguntas. En SEM, una matriz bien elaborada fortalece el modelo de medición y prepara una estimación más defendible (Churchill, 1979).

La especificación conceptual debe cerrar con una decisión de preparación: el instrumento está listo, requiere ajustes menores o necesita rediseño. Esta revisión debe hacerse antes de recolectar datos, porque corregir errores conceptuales después puede ser costoso o imposible. Si los constructos están mal definidos, si las dimensiones no se corresponden con los indicadores, si los informantes no pueden responder o si la escala mezcla fenómenos distintos, el modelo no debería avanzar todavía a campo. La calidad de SEM depende de decisiones tomadas antes de la estimación. Un buen software no corrige una mala especificación conceptual. Por ello, esta etapa funciona como control de calidad previo a la medición. El investigador debe recordar que **medir no consiste en preguntar muchas cosas, sino preguntar exactamente aquello que representa el constructo**. Cuando esta correspondencia existe, el modelo tiene mejores condiciones para ser interpretado con rigor (Henseler, 2017).

En conclusión, la **especificación conceptual antes de medir** es el puente entre la definición del constructo y la aplicación del instrumento. Su función es garantizar que

cada indicador corresponda al dominio conceptual, que las dimensiones estén bien representadas, que la unidad de análisis sea coherente, que el informante sea pertinente y que la escala de respuesta capture adecuadamente el fenómeno. Esta etapa evita errores frecuentes: mezclar antecedentes con resultados, confundir dimensiones con indicadores, usar ítems ambiguos, adaptar escalas sin pertinencia contextual o medir constructos mal delimitados. En el desarrollo progresivo del libro, este tema cierra el capítulo 4 porque prepara el paso hacia la evaluación de indicadores y modelos de medición en capítulos posteriores. La idea central es clara: **antes de medir, hay que especificar; antes de estimar, hay que alinear; antes de interpretar, hay que saber exactamente qué se midió** (Hair et al., 2021).

Conclusiones

El Capítulo 4 permitió comprender que el análisis estructural no inicia en el software ni en la estimación estadística, sino en la capacidad del investigador para transformar conceptos abstractos en constructos medibles. A lo largo del capítulo se mostró que existe una diferencia fundamental entre **concepto, variable y constructo**, ya que cada uno cumple una función distinta dentro del sistema de investigación. Mientras el concepto representa una idea teórica general, la variable permite observar variaciones empíricas y el constructo organiza dimensiones e indicadores para representar fenómenos complejos dentro de SEM (Churchill, 1979).

Asimismo, el capítulo destacó que gran parte de los fenómenos estudiados en ciencias de la administración son **constructos latentes**, es decir, entidades que no pueden observarse directamente y que requieren ser inferidas mediante variables observables. Esta condición obliga al investigador a construir indicadores coherentes con el dominio conceptual del constructo, evitando ambigüedades, redundancias y errores de especificación. En consecuencia, la calidad del modelo estructural dependerá en buena medida de la calidad conceptual de la medición (Jarvis et al., 2003).

Otro aprendizaje central fue la importancia de definir adecuadamente la **dimensionalidad del constructo**. El capítulo mostró que un constructo puede ser unidimensional, multidimensional o jerárquico, y que esta decisión debe derivarse de la teoría y del propósito investigativo. Definir incorrectamente la dimensionalidad puede producir escalas incompletas, constructos fragmentados o relaciones estructurales difíciles de interpretar. Por ello, antes de aplicar cualquier técnica estadística, el investigador debe comprender cómo está organizada internamente la entidad conceptual que desea medir (Hair et al., 2021).

También se concluyó que el desarrollo inicial de escalas exige una relación coherente entre definición conceptual, indicadores, contexto, informante y escala de respuesta. Una escala no debe construirse por acumulación de preguntas, sino mediante una arquitectura lógica que asegure pertinencia conceptual y capacidad de observación empírica. El capítulo enfatizó que los indicadores no son simples preguntas de cuestionario, sino representaciones metodológicas del constructo. En

este sentido, una mala escala no puede compensarse posteriormente mediante software o índices estadísticos (Henseler, 2017).

Finalmente, el capítulo cerró con la necesidad de realizar una **especificación conceptual antes de medir**. Esta etapa funciona como un control previo donde el investigador revisa si constructos, dimensiones, indicadores y unidad de análisis mantienen coherencia interna. Así, el capítulo deja preparada la transición hacia los temas posteriores relacionados con evaluación de medición, confiabilidad, validez y análisis estructural. La idea central es que **la medición rigurosa comienza mucho antes de calcular índices estadísticos; comienza cuando el investigador define con precisión qué significa realmente cada constructo dentro del modelo** (Hair et al., 2021). Véase la **Tabla 4.**

Tabla 4. Del concepto al constructo medible

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Alineación conceptual	Correspondencia entre constructo, dimensiones, indicadores y contexto.	Base lógica de la medición en SEM.	Debe existir antes de estimar relaciones estructurales.	Jarvis et al. (2003); Hair et al. (2021).
Claridad semántica	Comprensibilidad del lenguaje utilizado en los indicadores.	Reduce errores de interpretación.	Los ítems deben ser claros y específicos.	Churchill (1979); Jarvis et al. (2003).
Cobertura conceptual	Nivel en que la escala representa todas las partes esenciales del constructo.	Garantiza integridad de la medición.	Evita constructos incompletos o sesgados.	Churchill (1979); Jarvis et al. (2003).
Coherencia semántica	Correspondencia lógica entre definición, dimensiones e indicadores.	Asegura alineación conceptual del modelo.	Evita contradicciones e interpretaciones ambiguas.	Churchill (1979); Jarvis et al. (2003).
Concepto	Idea abstracta general utilizada para describir un fenómeno de interés científico.	Sirve como punto de partida teórico para construir variables y constructos.	Debe delimitarse claramente para evitar ambigüedad conceptual.	Churchill (1979); Hair et al. (2021).
Constructo	Entidad teórica no observable directamente, inferida mediante indicadores.	Constituye la unidad central del modelo de medición en SEM.	Debe tener definición conceptual clara y coherencia teórica.	Churchill (1979); Jarvis et al. (2003).
Constructo compuesto	Integración analítica de componentes que forman una	Representa estructuras complejas dentro de SEM.	Debe justificarse desde la lógica conceptual.	Henseler (2017); Hair et al. (2021).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	entidad conceptual.			
Constructo formativo	Constructo donde los indicadores forman o construyen el fenómeno.	Los indicadores aportan componentes distintos.	Los indicadores no necesariamente son intercambiables.	Diamantopoulos & Winklhofer (2001); Jarvis et al. (2003).
Constructo jerárquico	Constructo de orden superior formado por varias dimensiones o subconstructos.	Integra dimensiones dentro de una estructura más amplia.	Requiere justificación conceptual sólida.	Hair et al. (2021); Henseler (2017).
Constructo latente	Fenómeno abstracto que no puede observarse directamente, como confianza o satisfacción.	Es representado mediante variables observables.	Requiere indicadores válidos y coherentes conceptualmente.	Jarvis et al. (2003); Hair et al. (2021).
Constructo multidimensional	Constructo integrado por varias dimensiones relacionadas.	Permite representar fenómenos complejos.	Cada dimensión debe tener significado propio y coherente.	Jarvis et al. (2003); Hair et al. (2021).
Constructo reflectivo	Constructo donde los indicadores son manifestaciones del fenómeno latente.	Los indicadores reflejan cambios del constructo.	Se espera correlación conceptual entre indicadores.	Jarvis et al. (2003); Hair et al. (2021).
Constructo unidimensional	Constructo compuesto por una sola dimensión conceptual.	Facilita interpretación homogénea del constructo.	Los indicadores deben apuntar hacia una misma idea central.	Churchill (1979); Hair et al. (2021).
Dimensionalidad	Organización interna del constructo en una o varias dimensiones.	Determina la estructura conceptual del modelo de medición.	Debe derivarse de la teoría y no solo de la estadística.	Jarvis et al. (2003); Hair et al. (2021).
Dominio conceptual	Conjunto de contenidos legítimos que forman parte del constructo.	Delimita qué indicadores pertenecen o no al constructo.	Evita mezclar antecedentes, dimensiones y resultados.	Churchill (1979); Jarvis et al. (2003).
Escala de medición	Conjunto organizado de indicadores para medir un constructo.	Base empírica del modelo SEM.	Debe ser coherente con el fenómeno estudiado.	Churchill (1979); Hair et al. (2021).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Escala Likert	Escala ordinal basada en niveles de acuerdo o desacuerdo.	Permite medir percepciones y actitudes.	Muy utilizada en constructos reflectivos.	Churchill (1979); Hair et al. (2021).
Especificación conceptual	Revisión previa de alineación entre teoría, constructos e indicadores.	Control de calidad antes de medir y estimar.	Debe realizarse antes del análisis estadístico.	Jarvis et al. (2003); Hair et al. (2021).
Indicador	Manifestación observable utilizada para medir una dimensión o constructo.	Alimenta el modelo de medición.	Debe corresponder al dominio conceptual del constructo.	Churchill (1979); Jarvis et al. (2003).
Informante	Persona que proporciona los datos para medir los constructos.	Fuente empírica de información.	Debe tener conocimiento suficiente del fenómeno.	Gefen et al. (2000); Churchill (1979).
Matriz de operacionalización	Tabla que vincula constructos, dimensiones, indicadores y escalas.	Facilita organización conceptual del instrumento.	Ayuda a detectar omisiones o inconsistencias.	Churchill (1979); Hair et al. (2021).
Operacionalización	Proceso de traducir constructos abstractos en indicadores medibles.	Conecta teoría con datos empíricos.	Debe conservar el significado conceptual original.	Churchill (1979); Hair et al. (2021).
Parsimonia conceptual	Equilibrio entre simplicidad y cobertura conceptual.	Favorece modelos claros y manejables.	Un modelo no mejora por tener más indicadores.	Hair et al. (2021); Henseler (2017).
Pertinencia contextual	Adecuación de los indicadores al entorno y población estudiada.	Mejora la aplicabilidad empírica del instrumento.	Los ítems deben tener sentido para los participantes.	Henseler (2017); Hair et al. (2021).
Redundancia conceptual	Repetición innecesaria entre indicadores o dimensiones.	Puede afectar claridad y parsimonia del modelo.	Debe evitarse para reducir saturación y colinealidad.	Jarvis et al. (2003); Hair et al. (2021).
Respondibilidad	Capacidad del participante para responder adecuadamente un ítem.	Mejora calidad y validez de las respuestas.	El indicador debe corresponder a la experiencia del informante.	Churchill (1979); Gefen et al. (2000).
Sobreamplitud conceptual	Inclusión excesiva de significados dentro de un constructo.	Debilita precisión conceptual del modelo.	Produce indicadores heterogéneos y	Churchill (1979); Jarvis et al. (2003).

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
			relaciones ambiguas.	
Unidad de análisis	Nivel sobre el cual se realizan inferencias: individuo, grupo u organización.	Define quién responde y qué representan los datos.	Debe corresponder al constructo estudiado.	Gefen et al. (2000); Hair et al. (2021).
Validez de contenido	Nivel en que los indicadores representan adecuadamente el dominio conceptual.	Garantiza cobertura conceptual suficiente.	Debe revisarse antes de aplicar el instrumento.	Churchill (1979); Jarvis et al. (2003).
Variable	Propiedad observable o medible que puede variar entre individuos, grupos u organizaciones.	Permite operacionalizar relaciones dentro del modelo.	Debe expresar variación empírica significativa.	Churchill (1979); Hair et al. (2021).
Variable observable	Indicador empírico directamente medible mediante preguntas, registros o datos objetivos.	Representa empíricamente al constructo latente.	Debe ser clara, respondible y pertinente al contexto.	Churchill (1979); Hair et al. (2021).

Fuente: recopilación y elaboración propia

CAPÍTULO 5. PLS-SEM, del constructo al indicador

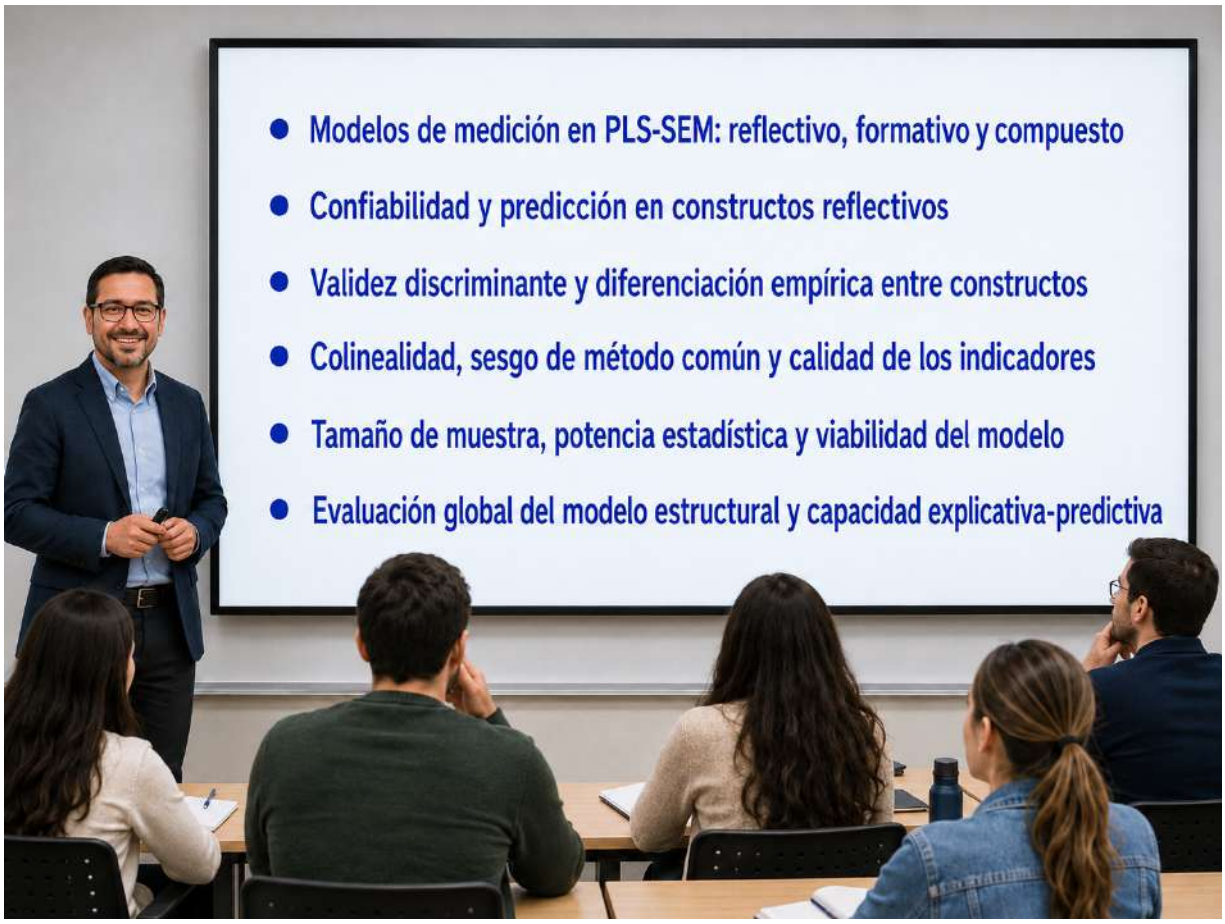

El Capítulo 5 desarrolla el tránsito entre la construcción conceptual del modelo y su evaluación empírica mediante **PLS-SEM**. En los capítulos anteriores, el investigador delimitó la idea, formuló el problema, organizó las relaciones teóricas, definió constructos y propuso indicadores. A partir de este punto, el desafío metodológico consiste en comprobar si esa arquitectura conceptual puede convertirse en un **modelo de medición técnicamente defendible**. PLS-SEM permite representar constructos latentes, indicadores y relaciones estructurales dentro de un sistema analítico orientado a explicar y, cuando corresponde, predecir variables endógenas. Sin embargo, esa flexibilidad exige que cada decisión de medición esté justificada antes de estimar el modelo. Por ello, este capítulo no inicia con los resultados, sino con la especificación del tipo de constructo, porque la forma en que se concibe la relación entre constructo e indicadores determina los criterios de evaluación posteriores (Chin, 1998)

El primer eje del capítulo es la distinción entre **constructos reflectivos, formativos, compuestos y jerárquicos**. Esta diferencia es fundamental porque no todos los constructos deben evaluarse con los mismos criterios. En los modelos reflectivos, los indicadores son manifestaciones de una variable latente común; por tanto, se espera consistencia interna, correlación entre ítems y evidencia de validez convergente. En los modelos formativos, en cambio, los indicadores contribuyen a formar el constructo, por lo que cada componente puede representar una faceta distinta del fenómeno y no necesariamente debe comportarse como intercambiable con los demás. Los compuestos y constructos jerárquicos agregan una capa adicional de complejidad, porque permiten representar fenómenos organizacionales amplios mediante componentes, dimensiones o constructos de orden inferior. Esta diferenciación evita un error frecuente: aplicar criterios reflectivos a estructuras que conceptualmente son formativas, compuestas o multidimensionales (Jarvis et al., 2003).

El segundo eje es la evaluación de la **calidad empírica del modelo de medición**. Una vez especificada la naturaleza del constructo, el investigador debe revisar si los indicadores funcionan de manera coherente con esa especificación. En constructos reflectivos, esto implica analizar cargas externas, alfa de Cronbach, rho_A, confiabilidad compuesta y varianza media extraída. En constructos formativos y compuestos, implica atender la relevancia conceptual, la colinealidad, los pesos externos, las cargas y la significancia de los indicadores. La confiabilidad y la validez convergente no deben entenderse como simples umbrales numéricos, sino como evidencia de que el constructo fue representado de manera suficientemente estable y coherente. Un valor aceptable no sustituye la teoría, pero una medición débil puede comprometer cualquier interpretación posterior del modelo estructural (Fornell & Larcker, 1981).

El tercer eje corresponde a la **diferenciación empírica entre constructos**. Un modelo puede mostrar confiabilidad aceptable y, aun así, ser problemático si dos constructos miden prácticamente el mismo fenómeno. Por ello, la validez discriminante ocupa un lugar central dentro del capítulo. Criterios como Fornell-Larcker, cargas cruzadas y especialmente HTMT permiten revisar si cada constructo conserva identidad propia frente a los demás. Esta revisión es decisiva porque las relaciones estructurales solo pueden interpretarse si los constructos conectados por una hipótesis son conceptualmente y empíricamente distinguibles. Si dos variables latentes no se diferencian, una relación entre ellas puede convertirse en una asociación redundante o tautológica. En ese sentido, la validez discriminante protege la lógica del modelo completo, no solo la calidad de una escala aislada (Henseler et al., 2015).

El cuarto eje analiza la **colinealidad, el sesgo de método común y la calidad de los indicadores**. Estos criterios permiten detectar si el modelo contiene redundancias, si los indicadores o constructos compiten por explicar el mismo contenido, o si las relaciones observadas podrían estar influidas por el procedimiento de recolección de datos. En PLS-SEM, el VIF funciona como una herramienta diagnóstica para revisar colinealidad en indicadores formativos, compuestos y predictores estructurales. Además, cuando los datos provienen de una misma fuente, en un mismo momento y

con un mismo instrumento, el investigador debe considerar el posible sesgo de método común. Esta revisión no invalida automáticamente un estudio, pero exige prudencia interpretativa y medidas preventivas o diagnósticas. Así, el capítulo muestra que la calidad del modelo no depende solo de la significancia de las relaciones, sino también de la limpieza conceptual y metodológica de los datos (Kock & Lynn, 2012).

Finalmente, el capítulo incorpora el análisis del **tamaño de muestra, la potencia estadística y la viabilidad del modelo**. Una medición conceptualmente sólida puede verse debilitada si la muestra no permite estimar con estabilidad los parámetros, evaluar hipótesis o sostener efectos complejos. La potencia estadística ayuda a valorar si el diseño empírico tiene condiciones suficientes para detectar efectos relevantes y evitar interpretaciones frágiles. Esta revisión conecta el modelo de medición con la viabilidad general del estudio: no basta con tener constructos bien definidos e indicadores adecuados; también se requiere una muestra compatible con la complejidad del modelo, el número de relaciones, la naturaleza de los constructos y el propósito explicativo o predictivo de la investigación. En conjunto, el Capítulo 5 muestra que antes de interpretar el modelo estructural, el investigador debe asegurar que sus constructos fueron correctamente especificados, medidos, diferenciados y estimados bajo condiciones metodológicas defendibles (Cohen, 1992).

Constructos reflectivos, formativos, compuestos y jerárquicos

El Capítulo 4 explicó la construcción conceptual del constructo, su dimensionalidad y su especificación antes de medir. En cambio, este tema aborda la **especificación técnica del modelo de medición en PLS-SEM**, es decir, la forma en que la arquitectura conceptual previamente definida se traduce en relaciones entre constructos e indicadores dentro del algoritmo. Esta frontera es importante para evitar que la evaluación del modelo de medición se convierta en una repetición de la teoría del constructo. En este punto, el investigador ya no pregunta qué es el constructo ni cuál es su dominio conceptual; pregunta **cómo será representado empíricamente**, qué dirección existe entre constructo e indicadores, qué modo de estimación resulta pertinente y qué criterios técnicos deben aplicarse para evaluar su calidad. Antes de revisar cargas externas, pesos, confiabilidad compuesta, AVE, HTMT, VIF o *bootstrapping*, debe decidirse si cada constructo será tratado como **reflectivo, formativo, compuesto o jerárquico**. En PLS-SEM, esta decisión es especialmente relevante porque el método permite trabajar con distintos tipos de modelos de medición, pero esa flexibilidad exige justificar cada especificación desde la teoría y no desde la comodidad del software (Chin, 1998; Hair et al., 2021).

Un **modelo reflectivo** se especifica cuando los indicadores funcionan como manifestaciones observables de un constructo latente común. En esta lógica, el constructo explica las respuestas de sus indicadores: si el nivel del constructo cambia, se espera que sus indicadores cambien en la misma dirección. Por ejemplo, constructos como satisfacción, confianza, compromiso, actitud o intención pueden

representarse de manera reflectiva cuando sus ítems expresan diferentes manifestaciones de una misma disposición subyacente. Esta especificación supone que los indicadores comparten varianza común, presentan correlaciones razonables entre sí y pueden ser parcialmente intercambiables sin alterar de manera sustantiva el significado del constructo. Por ello, los modelos reflectivos se evalúan mediante criterios como cargas externas, confiabilidad interna, confiabilidad compuesta, varianza media extraída y validez discriminante. Sin embargo, estos criterios solo son válidos cuando la relación conceptual entre constructo e indicadores es realmente reflectiva; una alta confiabilidad no corrige una mala especificación conceptual (Churchill, 1979; Fornell & Larcker, 1981; Hair et al., 2021).

Un **modelo formativo** se especifica cuando los indicadores no son manifestaciones del constructo, sino componentes que contribuyen a formarlo. En este caso, la dirección conceptual va de los indicadores hacia el constructo. Esto significa que cada indicador aporta una parte del significado total y que eliminar uno de ellos puede modificar el dominio conceptual representado. Por ejemplo, una capacidad digital organizacional podría formarse mediante infraestructura tecnológica, competencias digitales, uso de analítica, automatización de procesos y cultura digital. Estos componentes no necesitan estar altamente correlacionados, porque representan facetas distintas de una entidad más amplia. Por ello, no deben evaluarse con criterios propios de modelos reflectivos, como consistencia interna o AVE. En los modelos formativos, la evaluación debe centrarse en la pertinencia conceptual de los indicadores, la colinealidad, los pesos externos, la significancia y la relevancia de cada componente. Tratar un constructo formativo como reflectivo puede llevar a eliminar indicadores necesarios solo porque no presentan cargas elevadas, empobreciendo así el significado del constructo (Diamantopoulos & Winklhofer, 2001; Jarvis et al., 2003; Hair et al., 2021).

Un **modelo compuesto** se especifica cuando el investigador construye una entidad analítica mediante la combinación de indicadores que representan componentes funcionales del fenómeno. La lógica compuesta es especialmente útil en PLS-SEM porque muchos estudios en administración no buscan estimar un factor común latente, sino representar capacidades, recursos, prácticas, rutinas o resultados heterogéneos que adquieren sentido al integrarse. Por ejemplo, transformación digital, madurez organizacional, capacidad de innovación o desempeño sostenible pueden conceptualizarse como compuestos cuando se definen como combinaciones de elementos diferenciados. En estos casos, los indicadores no son intercambiables ni necesariamente homogéneos; su valor depende de la contribución que realizan al constructo construido. Por ello, un compuesto debe justificarse teóricamente, evaluarse con criterios acordes a su naturaleza y evitar ser tratado como si fuera un constructo reflectivo puro. Esta distinción es importante porque PLS-SEM opera con componentes y permite representar fenómenos complejos, pero esa posibilidad metodológica requiere claridad conceptual y transparencia en la especificación (Guenther et al., 2023).

La diferencia entre modelos reflectivos, formativos y compuestos debe resolverse antes de ejecutar el algoritmo, no después de observar los resultados. Una forma práctica de tomar esta decisión consiste en formular preguntas de diagnóstico. Primero: **¿el constructo causa los indicadores o los indicadores forman el constructo?** Segundo: **¿los indicadores son intercambiables o cada uno representa una faceta necesaria?** Tercero: **¿todos los indicadores deberían cambiar en la misma dirección si cambia el constructo?** Cuarto: **¿eliminar un indicador modifica el significado del constructo?** Si los indicadores son manifestaciones de una variable latente común, la especificación tiende a ser reflectiva. Si los indicadores componen el dominio conceptual, la especificación tiende a ser formativa o compuesta. Estas preguntas obligan al investigador a justificar la medición desde la teoría y evitan decisiones mecánicas basadas únicamente en cargas, pesos o criterios automáticos del software (Hair et al., 2021).

El **análisis de tétradas confirmatorio** puede incorporarse como una herramienta complementaria para examinar si la especificación reflectiva de un constructo es empíricamente defendible. Su utilidad aparece cuando existe duda sobre si los indicadores son **manifestaciones intercambiables** de una variable latente común o si, por el contrario, funcionan como **componentes necesarios** que forman el significado del constructo. En una lógica reflectiva, los indicadores deberían compartir una fuente común de varianza y comportarse como expresiones del mismo fenómeno subyacente; por ello, ciertas combinaciones de covarianzas entre indicadores deberían aproximarse a cero. Cuando una tétrada no redundante resulta significativamente distinta de cero, se genera una señal de posible mala especificación del modelo de medición. Sin embargo, el CTA no debe interpretarse como una regla automática para decidir si un constructo es reflectivo, formativo o compuesto. Su función es **alertar al investigador** cuando la evidencia empírica no coincide con la especificación propuesta. La decisión final debe seguir dependiendo de la teoría, de la definición conceptual del constructo y de la función que cumplen los indicadores dentro del modelo de medición (Gudergan et al., 2008).

La especificación del modelo de medición también debe considerar los **constructos jerárquicos o de orden superior**, especialmente cuando un constructo se representa mediante dimensiones de primer orden. En esta configuración, el constructo de orden superior, o **HOC**, expresa el concepto general, mientras que los constructos de orden inferior, o **LOC**, representan dimensiones específicas. Esta estrategia es útil cuando el investigador desea modelar conceptos complejos con mayor parsimonia, reducir el número de relaciones estructurales y representar un nivel de abstracción superior. Por ejemplo, una capacidad organizacional puede estar formada por dimensiones tecnológicas, humanas y estratégicas; cada dimensión puede medirse mediante sus propios indicadores, mientras que el constructo superior sintetiza el fenómeno amplio que se desea analizar. Esta lógica debe ubicarse en el Capítulo 5 porque ya no trata solo de definir la dimensionalidad conceptual del constructo, sino de decidir **cómo se estima técnicamente esa estructura jerárquica en PLS-SEM** (Becker et al., 2012).

Los constructos jerárquicos pueden adoptar distintas configuraciones según la relación entre el **constructo de orden superior (HOC), los constructos de orden inferior (LOC)** y los indicadores. La literatura distingue cuatro tipos principales: **reflectivo-reflectivo**, **reflectivo-formativo**, **formativo-reflectivo** y **formativo-formativo**. En el tipo reflectivo-reflectivo, el constructo superior se manifiesta en dimensiones de primer orden que también se miden reflectivamente. En el tipo reflectivo-formativo, los LOC reflectivos forman el HOC. En el tipo formativo-reflectivo, el HOC se manifiesta en dimensiones que internamente se miden de forma formativa. En el tipo formativo-formativo, tanto los LOC como el HOC responden a una lógica de composición. Esta tipología no debe presentarse como una clasificación decorativa, sino como una decisión metodológica que afecta la evaluación del modelo, la interpretación de los resultados y los criterios que se aplicarán a cada parte de la medición (Hair et al., 2021).

En PLS-SEM, los constructos jerárquicos deben entenderse desde una lógica de **componentes agregados**. A diferencia de enfoques estrictamente factoriales, PLS-SEM trabaja con componentes, por lo que los modelos multidimensionales se estiman considerando la varianza agregada o total asociada a las dimensiones. Si se emplea una lógica cercana al **Modo A**, se espera que las dimensiones compartan una varianza común relevante; si se emplea una lógica cercana al **Modo B**, no se exige necesariamente alta correlación entre dimensiones, porque cada una puede aportar un componente distinto del constructo superior. Esta precisión evita interpretar de manera incorrecta los LOC como simples manifestaciones intercambiables cuando, en realidad, pueden operar como componentes necesarios de una estructura más amplia. Por ello, un HOC no debe especificarse solo para simplificar el diagrama, sino porque la teoría indica que varias dimensiones representan una estructura conceptual superior coherente (Sarstedt et al., 2019).

Para estimar constructos jerárquicos en PLS-SEM existen tres enfoques principales: **indicadores repetidos**, **enfoque integrado de dos etapas** y **enfoque disociado de dos etapas**. El enfoque de indicadores repetidos asigna al HOC todos los indicadores de los LOC, por lo que resulta intuitivo y relativamente sencillo cuando las dimensiones tienen un número equilibrado de indicadores. Sin embargo, puede generar problemas en configuraciones reflectivo-formativas o formativo-formativas, especialmente cuando un HOC con relaciones formativas hacia sus dimensiones funciona como variable dependiente. En ese caso puede aparecer un problema de $R^2 = 1$, porque el constructo superior queda explicado perfectamente por sus dimensiones y los caminos provenientes de variables antecedentes pueden estimarse como nulos o no significativos. Esta advertencia es importante porque evita interpretar como ausencia de efecto lo que en realidad puede ser una consecuencia de la especificación del modelo jerárquico (Becker et al., 2012; Ringle et al., 2012; Sarstedt et al., 2019).

El **enfoque integrado de dos etapas** permite estimar primero el modelo para obtener las puntuaciones o scores de los constructos y, en una segunda etapa, utilizar esas puntuaciones como indicadores del constructo de orden superior. Esta estrategia puede ser útil cuando el investigador desea conservar la lógica estructural general del

modelo y, al mismo tiempo, reducir problemas derivados de la asignación repetida de indicadores. El **enfoque disociado de dos etapas**, por su parte, separa con mayor claridad la estimación de los LOC y del HOC. En una primera etapa, se estima el modelo sin el constructo de orden superior para obtener las puntuaciones de los constructos de primer orden; en una segunda etapa, esas puntuaciones se emplean para medir el constructo superior. Este enfoque es especialmente útil cuando se busca una estimación más estable de modelos jerárquicos complejos y cuando se desea evitar distorsiones asociadas al uso directo de indicadores repetidos. Se desarrolla este procedimiento operativo al indicar que las puntuaciones de variables latentes de los constructos de orden inferior pueden guardarse y luego asignarse como indicadores del constructo de orden superior en la segunda etapa.

La elección entre indicadores repetidos, enfoque integrado de dos etapas y enfoque disociado de dos etapas debe responder al objetivo de la investigación, a la posición del HOC dentro del modelo, a la naturaleza reflectiva, formativa o compuesta de sus dimensiones y a la necesidad de estimar con claridad los caminos estructurales entrantes y salientes. Si el interés principal es una especificación simple del modelo jerárquico y las dimensiones tienen indicadores equilibrados, el enfoque de indicadores repetidos puede ser suficiente. Si el interés es mejorar la estimación de efectos estructurales o evitar problemas derivados de un HOC formativo dependiente, los enfoques de dos etapas suelen ser más adecuados. Esta decisión debe reportarse explícitamente: qué enfoque se utilizó, por qué se eligió, cómo se obtuvieron los scores, qué constructos fueron tratados como LOC, cómo se especificó el HOC y qué criterios se aplicaron para evaluar la medición resultante. Con ello, la especificación del modelo de medición deja de ser una operación técnica invisible y se convierte en una decisión metodológica defendible (Becker et al., 2012; Sarstedt et al., 2019; Schuberth et al., 2020).

En síntesis, este tema cumple una función organizadora dentro del Capítulo 5: define **qué tipo de medición corresponde a cada constructo** antes de aplicar criterios de confiabilidad, validez, colinealidad, significancia o evaluación estructural. Los constructos reflectivos deben evaluarse con cargas, confiabilidad, AVE y validez discriminante; los formativos y compuestos requieren pesos, relevancia conceptual, significancia y VIF; los jerárquicos exigen decidir si se estimarán mediante indicadores repetidos o enfoques de dos etapas. Esta separación protege la ortogonalidad del libro: el Capítulo 4 define conceptualmente el constructo y su dimensionalidad; el Capítulo 5 traduce esa arquitectura en una especificación técnica PLS-SEM; y los temas posteriores del mismo capítulo aplican criterios de evaluación según la naturaleza de la medición. Así, el investigador no avanza a los índices como si fueran una lista universal, sino como consecuencia lógica de una especificación previamente justificada (Hair et al., 2019; Hair et al., 2021; Guenther et al., 2023).

Confiabilidad y validez convergente en constructos reflectivos

La **confiabilidad de los indicadores** y la **consistencia interna** constituyen una etapa decisiva en la evaluación del modelo de medición reflectivo, porque permiten determinar si los ítems asignados a cada constructo funcionan como manifestaciones empíricas estables de una variable latente. Después de haber especificado, si un constructo es **reflectivo, formativo o compuesto**, el investigador debe aplicar criterios acordes con esa naturaleza. En los **constructos reflectivos**, los indicadores se interpretan como efectos observables del constructo; por ello, se espera que estén asociados entre sí y que compartan una proporción suficiente de varianza con la variable latente. Esta sección no vuelve a definir qué es un constructo, ni reconstruye la escala desde cero; su propósito es verificar si la medición ya planteada posee **calidad empírica mínima** para continuar con la validez convergente, la validez discriminante y el modelo estructural. En PLS-SEM, esta evaluación inicia con las **cargas externas**, continúa con **alfa de Cronbach, rho_A y rho_c**, y posteriormente se complementa con criterios de validez. Además, aunque los índices predictivos como ***Q²*** **de Stone-Geisser, PLSpredict, RMSE, MAE y *Q²*** **_predict** no pertenecen estrictamente a la confiabilidad interna, conviene introducirlos como transición metodológica, porque un modelo bien medido debe estar preparado para explicar y, cuando el propósito lo exige, predecir constructos endógenos. **La medición confiable no garantiza predicción; sin embargo, una medición deficiente debilita cualquier pretensión predictiva posterior** (Hair et al., 2021).

La **confiabilidad del indicador** se evalúa principalmente mediante la **carga externa** (*outer loading*), que expresa la relación entre cada indicador y el constructo reflectivo al que pertenece. Una carga elevada significa que el indicador comparte una proporción importante de varianza con el constructo; una carga débil puede indicar problemas de redacción, falta de correspondencia conceptual, adaptación deficiente al contexto o baja comprensión por parte de los respondientes. En PLS-SEM, se recomienda que las cargas externas sean iguales o superiores a **0.708**, porque al elevar ese valor al cuadrado se obtiene una varianza explicada superior al 50%. En otras palabras, el constructo explica más de la mitad de la variación del indicador, lo cual sugiere una confiabilidad individual aceptable. Sin embargo, este criterio debe funcionar como **regla orientativa**, no como mandato automático. En investigaciones sociales, administrativas o de innovación, sobre todo cuando se desarrollan escalas nuevas o adaptadas, pueden encontrarse cargas entre **0.40 y 0.708**. En ese rango, el investigador debe revisar si la eliminación del indicador mejora la confiabilidad interna o la validez convergente, pero también si afecta la **validez de contenido**. Los indicadores con cargas inferiores a **0.40** suelen eliminarse, salvo justificación extraordinaria. **Depurar indicadores no significa perseguir cifras perfectas, sino conservar aquellos que representan mejor el constructo sin sacrificar su contenido conceptual** (Hair et al., 2019).

La eliminación de indicadores reflectivos debe equilibrar la evidencia estadística con el juicio teórico. Una escala puede mejorar sus valores numéricos y, al mismo tiempo, perder riqueza conceptual. Por ejemplo, si una escala de confianza organizacional incluye indicadores de honestidad, competencia, benevolencia, previsibilidad y seguridad, eliminar un ítem con carga moderada podría elevar ligeramente la confiabilidad, pero también suprimir una faceta relevante del constructo. Por eso, la pregunta metodológica no debe ser únicamente **"¿cuánto carga este indicador?"**, sino también **"¿qué dimensión del constructo se perdería si este indicador se elimina?"**. Esta precaución es especialmente importante en constructos complejos como innovación sostenible, capacidades dinámicas, transformación digital, aprendizaje organizacional o desempeño institucional, donde los indicadores no siempre poseen la misma fuerza empírica, pero sí pueden aportar matices necesarios. Una escala compuesta solo por ítems muy similares puede mostrar alta consistencia interna, aunque en realidad mida una versión estrecha del fenómeno. La confiabilidad, por tanto, debe entenderse como estabilidad empírica con suficiencia conceptual. **Una escala sólida no es la que elimina todo indicador imperfecto, sino la que conserva una representación clara, parsimoniosa y suficientemente amplia del constructo** (Churchill, 1979).

La **consistencia interna** evalúa si los indicadores de un constructo reflectivo se comportan como manifestaciones coherentes de una misma variable latente. Esta evaluación es pertinente porque, en la lógica reflectiva, los indicadores comparten una causa común. Si aumenta la satisfacción, la confianza, el compromiso o la actitud favorable, se espera que los ítems asociados a ese constructo se muevan en una dirección semejante. Cuando los indicadores no se relacionan entre sí, puede existir un problema de medición: los ítems quizá pertenecen a dimensiones diferentes, algunos pueden estar mal redactados, otros pueden medir un fenómeno distinto o el constructo pudo haber sido especificado incorrectamente. Los índices más usados para evaluar esta coherencia son **alfa de Cronbach, rho_A y rho_c**. El alfa ofrece una aproximación clásica basada en correlaciones entre ítems; rho_A ofrece una estimación más consistente de confiabilidad en modelos reflectivos; y rho_c, o confiabilidad compuesta, pondera los indicadores conforme a sus cargas. Estos índices no deben verse como equivalentes perfectos, sino como evidencias complementarias. En general, valores superiores a **0.70** son aceptables, mientras que valores superiores a **0.95** pueden indicar redundancia. **La consistencia interna demuestra coherencia entre indicadores, pero no demuestra por sí sola que el constructo sea válido** (Fornell & Larcker, 1981).

El **alfa de Cronbach** es el índice más tradicional para estimar la consistencia interna de una escala. Su utilidad radica en proporcionar una medida general de homogeneidad entre indicadores, a partir de la correlación promedio entre ellos. En términos orientativos, valores de **0.70 o superiores** suelen aceptarse como evidencia de confiabilidad; valores entre **0.60 y 0.70** pueden ser tolerables en estudios exploratorios; y valores inferiores sugieren revisar redacción, dimensionalidad, pertinencia o número de indicadores. Sin embargo, un alfa alto no siempre significa mejor medición. La adición de ítems muy parecidos puede elevar artificialmente el

coeficiente, aunque no mejore la representación conceptual del constructo. Además, el alfa presupone que los indicadores contribuyen de manera relativamente equivalente, supuesto que no siempre se cumple en escalas aplicadas a ciencias sociales. Por ello, el alfa debe interpretarse como **evidencia inicial**, no como prueba definitiva de calidad. En el diseño de escalas, también debe revisarse la longitud del instrumento, la claridad de los ítems, la redundancia, la correlación interítem y la estructura dimensional. Una escala puede ser confiable por repetitiva, pero pobre en cobertura conceptual. **El alfa de Cronbach ayuda a evaluar consistencia, pero no sustituye el análisis conceptual ni la valoración de validez** (Mejía-Trejo, 2023).

El índice **rho_A**, conocido como **Dijkstra-Henseler's rho**, requiere una explicación específica porque suele confundirse con la confiabilidad compuesta. En realidad, **rho_A no es rho_c**. Dijkstra y Henseler introducen rho_A en el marco de **consistent partial least squares *path* modeling** o **PLSc**, con el objetivo de atender problemas de consistencia cuando PLS se aplica a modelos con medición reflectiva. El argumento central es que, si los constructos reflectivos contienen error de medición, las estimaciones de relaciones entre constructos pueden quedar atenuadas o sesgadas, afectando incluso la prueba de hipótesis. En este contexto, rho_A funciona como un coeficiente de confiabilidad más consistente que el alfa de Cronbach y menos liberal que la confiabilidad compuesta. Por ello, suele ubicarse entre ambos valores. Su utilidad no es solamente descriptiva; tiene implicaciones inferenciales, porque una estimación inadecuada de la confiabilidad puede influir en las correlaciones entre constructos, los coeficientes *path* y los errores tipo I o tipo II. En el reporte metodológico, rho_A debe presentarse junto con alfa y rho_c, pero diferenciando su significado. **rho_A corresponde al coeficiente de Dijkstra-Henseler; rho_c corresponde a la confiabilidad compuesta** (Dijkstra & Henseler, 2015).

El índice **rho_c**, también llamado **confiabilidad compuesta**, **composite reliability**, **CR** o **IFC**, evalúa la consistencia interna considerando las cargas reales de los indicadores. Esto lo hace especialmente útil en SEM y PLS-SEM, donde los indicadores rara vez contribuyen de manera idéntica al constructo. A diferencia del alfa de Cronbach, que tiende a asumir una contribución más homogénea de los ítems, rho_c pondera la fuerza empírica de cada indicador. En términos orientativos, valores entre **0.70 y 0.90** se consideran satisfactorios; valores entre **0.60 y 0.70** pueden aceptarse en investigación exploratoria; y valores superiores a **0.95** deben revisarse por posible redundancia. Un resultado como **rho_c = 0.939** indica **alta consistencia interna**. Supera ampliamente el mínimo de 0.70 y permanece por debajo del límite crítico de 0.95, por lo que puede considerarse aceptable. No obstante, al estar cerca del umbral superior, conviene revisar si los indicadores son demasiado similares o si existe repetición semántica. En un reporte académico, debe explicarse que **rho_c = 0.939** significa que los indicadores representan de forma muy consistente al constructo reflectivo, pero no debe confundirse con rho_A. **rho_c = 0.939 es confiabilidad compuesta alta; no es Dijkstra-Henseler's rho** (Hair et al., 2021).

La **redundancia de indicadores** aparece cuando una escala incluye ítems tan semejantes que elevan la confiabilidad sin aportar información conceptual nueva. Este

problema es frecuente cuando se busca maximizar alfa, rho_A o rho_c sin atender la amplitud del constructo. Valores superiores a **0.90** deben revisarse y valores mayores a **0.95** pueden sugerir que los indicadores son prácticamente repetitivos. La redundancia tiene varios riesgos: reduce la validez de contenido, cansa al participante, favorece respuestas automáticas y puede inflar correlaciones entre errores. En el caso de **rho_c = 0.939**, el valor es positivo porque se mantiene por debajo de 0.95; sin embargo, el investigador debe verificar que los indicadores no sean simples paráfrasis. La pregunta adecuada es: **¿cada ítem aporta un matiz útil del constructo o todos repiten el mismo contenido?**. Si los indicadores son claros, relacionados y no redundantes, el valor 0.939 fortalece el modelo de medición. Si los ítems son casi idénticos, el índice alto podría ocultar un problema de diseño de escala. La confiabilidad ideal no consiste en alcanzar el máximo valor posible, sino en mantener una medición estable, parsimoniosa y conceptualmente suficiente. **Una confiabilidad excesiva puede ser señal de precisión aparente y pobreza conceptual real** (Hair et al., 2019).

La **validez predictiva de una escala** debe distinguirse de la confiabilidad interna. Una escala puede ser internamente consistente y, aun así, tener escasa capacidad para anticipar un resultado relevante. Por ejemplo, una escala de actitud hacia la innovación puede presentar alfa, rho_A y rho_c aceptables, pero todavía debe demostrar si se relaciona con intención de adopción, desempeño innovador o comportamiento real. La confiabilidad responde la pregunta: **¿los indicadores miden de forma estable el constructo?**. La validez predictiva responde otra pregunta: **¿el constructo medido permite anticipar un criterio externo o un resultado posterior?**. En el diseño de escalas, esta diferencia es fundamental porque una medición estable no necesariamente tiene utilidad explicativa o predictiva. En PLS-SEM, la validez predictiva se vincula con la evaluación de constructos endógenos y con la capacidad del modelo para generar predicciones útiles. Por ello, en el tema 5.2 se puede introducir la validez predictiva como puente, pero no debe confundirse con confiabilidad. Primero se verifica que la escala sea consistente; luego se evalúa si esa escala contribuye a explicar o predecir un resultado dentro del modelo. **La confiabilidad es condición necesaria para la predicción, pero no prueba por sí misma capacidad predictiva** (Mejía-Trejo, 2023).

El ***Q²*** **de Stone-Geisser** evalúa la **relevancia predictiva** del modelo a través del procedimiento de **blindfolding**. Este índice se usa principalmente para constructos endógenos y busca determinar si el modelo tiene capacidad para reconstruir valores omitidos. En términos generales, un valor ***Q²* > 0** indica que el modelo posee relevancia predictiva para el constructo evaluado. Sin embargo, es muy importante no sobreinterpretarlo. El *Q²* de Stone-Geisser no equivale a una prueba completa de predicción fuera de muestra, porque el procedimiento de blindfolding no utiliza una muestra de retención independiente. Su ventaja es que puede aplicarse sin reservar un subconjunto de datos, pero precisamente por ello no debe confundirse con una evaluación predictiva más exigente. Guenther et al. señalan que el *Q²* basado en blindfolding fue sugerido tempranamente en la literatura PLS-SEM, pero no representa propiamente una evaluación de capacidad predictiva fuera de muestra. Por tanto, debe

interpretarse como **relevancia predictiva interna**, no como evidencia definitiva de predicción futura. ***Q²* de Stone-Geisser sirve como señal inicial de relevancia predictiva, pero debe complementarse con PLSpredict cuando se desea evaluar predicción fuera de muestra**. El procedimiento **PLSpredict** permite evaluar la **capacidad predictiva fuera de muestra** mediante validación cruzada. A diferencia del *Q²* de Stone-Geisser, PLSpredict divide la muestra en subconjuntos o *folds*. Una parte de los datos se utiliza como muestra de entrenamiento y otra parte como muestra de retención. El modelo se estima con la muestra de entrenamiento y predice los casos que no fueron usados para estimarlo. Este proceso se repite hasta que todas las observaciones han sido predichas al menos una vez. En la práctica, se suele recomendar **k = 10**, aunque el investigador debe asegurarse de que el tamaño de muestra sea suficiente en cada partición. Además, debido a que la asignación de casos a los folds es aleatoria, se recomienda ejecutar el procedimiento varias veces y promediar los errores, evitando que una partición extrema distorsione los resultados. PLSpredict responde una pregunta distinta a la confiabilidad y a la varianza explicada: **¿qué tan bien predice el modelo casos no usados en la estimación?** Esta pregunta es crucial cuando el estudio tiene orientación aplicada o causal-predictiva. La evaluación debe considerar *Q²* _predict, los errores de predicción y la comparación con un punto de referencia. Si los errores presentan una distribución aproximadamente simétrica, puede emplearse RMSE; si la distribución no es suficientemente simétrica, conviene utilizar MAE. En ambos casos, los errores del modelo PLS-SEM deben compararse con un benchmark, como un modelo lineal, porque la predicción no se defiende por el valor aislado de un índice, sino por su capacidad para reducir error frente a una alternativa razonable (Guenther et al., 2023).

Dentro de PLSpredict, los índices **RMSE** y **MAE** cuantifican el error de predicción. El **RMSE** (*root mean squared error*) calcula la raíz cuadrada del promedio de los errores al cuadrado. Como eleva los errores antes de promediarlos, penaliza con mayor fuerza las desviaciones grandes. Por ello, es útil cuando los errores amplios son especialmente problemáticos, como en predicciones empresariales, financieras, operativas o de desempeño. El **MAE** (*mean absolute error*) calcula el promedio de los errores absolutos y no distingue si el modelo sobrestima o subestima; simplemente mide la magnitud media del error. Al no elevar los errores al cuadrado, puede ser menos sensible a valores extremos que el RMSE. Ninguno de estos índices posee un umbral universal, porque su interpretación depende de la escala de la variable predicha. Por eso, deben compararse contra un **benchmark**, como un modelo lineal o una predicción ingenua basada en la media de la muestra de entrenamiento. Si el modelo PLS-SEM presenta errores menores que el benchmark, su capacidad predictiva será más defendible. **RMSE y MAE no se interpretan aislados; su valor depende de si reducen el error frente a una alternativa de comparación** (Hair et al., 2021).

El índice *Q²* _predict se utiliza en el contexto de PLSpredict para valorar si el modelo supera una predicción ingenua. En términos generales, un ***Q²* _predict > 0** indica que el modelo predice mejor que un benchmark básico, usualmente basado en la media de la muestra de entrenamiento. Sin embargo, este índice tampoco debe

interpretarse de manera aislada. Debe revisarse junto con **RMSE** o **MAE**, porque un valor positivo puede no ser suficiente si los errores del modelo PLS-SEM son mayores que los de un modelo lineal comparativo. La evaluación predictiva debe centrarse especialmente en el **constructo endógeno clave**, no necesariamente en todos los indicadores de todos los constructos endógenos. Esta recomendación es importante porque evita sobrecargar el reporte con resultados periféricos y orienta el análisis hacia el objetivo principal del modelo. Si la mayoría de los indicadores del constructo endógeno principal tienen errores menores en PLS-SEM que en el benchmark, puede sostenerse una capacidad predictiva relevante. Si no, la predicción será limitada aunque el modelo tenga buen R^2 . **Q^2 _predict ayuda a determinar si el modelo anticipa observaciones no usadas para estimarlo, pero debe leerse con los errores de predicción y con benchmarks adecuados** (Guenther et al., 2023).

La incorporación de índices predictivos dentro del tema debe hacerse con una advertencia metodológica: **no son índices de confiabilidad interna**. **Alfa de Cronbach, rho_A y rho_c** pertenecen a la evaluación del modelo de medición reflectivo. En cambio, **Q^2 de Stone-Geisser, PLSpredict, RMSE, MAE y Q^2 _predict** pertenecen a la evaluación predictiva del modelo, generalmente asociada con constructos endógenos y con la fase estructural. No obstante, incluirlos aquí tiene valor pedagógico porque ayuda al lector a comprender la ruta completa: primero se revisa si los indicadores miden de forma confiable; luego se evalúa si el constructo converge y se distingue de otros; después se analiza si las relaciones estructurales son significativas y relevantes; finalmente, si el objetivo lo exige, se prueba si el modelo predice. Esta secuencia evita confundir medición con predicción. Una escala confiable no garantiza que el modelo prediga bien, pero una escala no confiable vuelve sospechosa cualquier evaluación predictiva posterior. **El orden lógico es: medición confiable, validez aceptable, estructura coherente y predicción evaluada con criterios específicos** (Hair et al., 2019).

En síntesis, se presenta una visión ampliada de la evaluación de constructos reflectivos. Las **cargas externas** muestran si cada indicador representa adecuadamente al constructo; el **alfa de Cronbach** ofrece una primera aproximación a la consistencia interna; **rho_A** debe explicarse como **Dijkstra-Henseler's rho**, vinculado con la confiabilidad consistente en modelos reflectivos; y **rho_c** debe entenderse como **confiabilidad compuesta**, ponderada por las cargas de los indicadores. Un resultado como **rho_c = 0.939** debe interpretarse como **alta confiabilidad compuesta**, aceptable y cercana al límite superior, por lo que exige revisar posible redundancia sin considerarse problemático automáticamente. A su vez, los criterios predictivos deben ubicarse correctamente: **Q^2 de Stone-Geisser** aporta evidencia de relevancia predictiva mediante blindfolding; **PLSpredict** evalúa predicción fuera de muestra; **RMSE** y **MAE** cuantifican errores de predicción; y **Q^2 _predict** permite valorar si el modelo supera un benchmark ingenuo. Así, el investigador comprende que la confiabilidad es la base, pero no el punto final. **Un modelo PLS-SEM riguroso debe medir bien, reportar confiabilidad diferenciada y, cuando corresponda, demostrar capacidad predictiva con procedimientos adecuados.**

Los criterios de confiabilidad interna, validez convergente y consistencia desarrollados en este apartado corresponden principalmente a modelos **de medición reflectivos,** debido a que sus indicadores se asumen como manifestaciones correlacionadas del constructo latente. En constructos formativos y compuestos, la lógica de evaluación difiere, ya que los indicadores contribuyen a formar el constructo y no necesariamente requieren alta correlación interna. Por ello, su evaluación incorpora criterios específicos relacionados con colinealidad, relevancia conceptual, pesos externos y estabilidad estructural, los cuales serán retomados posteriormente en el desarrollo metodológico del modelo PLS-SEM (Hair et al., 2021).

Validez discriminante y diferenciación empírica entre constructos

L**a validez discriminante es el criterio que permite evaluar si los constructos incluidos en un modelo SEM son empíricamente distintos entre sí**. Después de revisar la confiabilidad, la consistencia interna, las cargas externas, la varianza media extraída y los criterios predictivos básicos en constructos reflectivos, el siguiente paso consiste en comprobar que cada constructo conserva una identidad propia dentro del modelo. Esta evaluación es indispensable porque un modelo puede mostrar buenos niveles de confiabilidad y validez convergente, pero aun así presentar problemas si dos constructos miden prácticamente el mismo fenómeno. Por ejemplo, **satisfacción**, **confianza**, **compromiso** y **lealtad** pueden estar teóricamente relacionadas, pero no deben confundirse como si fueran una sola entidad. En PLS-SEM, la validez discriminante protege la interpretación posterior de los coeficientes estructurales, porque las relaciones entre constructos solo tienen sentido si los constructos son distinguibles. Si dos variables latentes no se diferencian, cualquier relación entre ellas puede volverse tautológica o difícil de defender. Por ello, la validez discriminante no debe entenderse como un trámite estadístico, sino como una verificación doble: **conceptual**, porque exige definiciones claras; y **empírica**, porque requiere evidencia de diferenciación en los datos (Henseler et al., 2015).

La primera condición para lograr validez discriminante es la diferenciación conceptual previa. Antes de revisar matrices, ratios o cargas cruzadas, el investigador debe haber establecido con precisión qué significa cada constructo y qué lo distingue de otros constructos cercanos. En ciencias de la administración, muchos conceptos se encuentran naturalmente relacionados: **capacidad digital**, **madurez digital**, **transformación digital** y **uso de tecnología** pertenecen al mismo campo, pero no necesariamente representan lo mismo. Si el investigador no delimita sus fronteras, los indicadores pueden terminar midiendo contenidos equivalentes. En ese caso, el problema no nace en el análisis estadístico, sino en la especificación teórica. La validez discriminante comienza cuando se redactan las definiciones conceptuales y se decide qué dimensiones pertenecen a cada constructo. Si dos constructos comparten demasiados indicadores, lenguaje o dominio conceptual, es probable que más adelante aparezcan valores HTMT elevados o cargas cruzadas problemáticas. Por tanto, la evaluación empírica no sustituye el trabajo conceptual; **lo confirma, lo**

cuestiona o exige corregirlo. Un modelo SEM sólido exige que cada constructo tenga una **frontera conceptual defendible** antes de ser estimado (Jarvis et al., 2003).

Una forma tradicional de evaluar validez discriminante es el criterio de Fornell-Larcker. Este criterio compara la raíz cuadrada de la varianza media extraída de cada constructo con sus correlaciones con otros constructos. En términos sencillos, se espera que un constructo comparta más varianza con sus propios indicadores que con otros constructos del modelo. Si esto ocurre, existe evidencia inicial de que el constructo se diferencia de los demás. Sin embargo, aunque este criterio ha sido ampliamente utilizado en SEM, actualmente se reconoce que puede ser insuficiente para detectar problemas de validez discriminante, especialmente cuando los constructos están altamente correlacionados. Por ello, no conviene usarlo como único criterio. Su valor es orientativo, útil para una primera lectura, pero debe complementarse con criterios más sensibles. En la práctica, si Fornell-Larcker se cumple, el investigador no debe asumir automáticamente que la discriminación está resuelta. Debe revisar también HTMT, cargas cruzadas, definiciones conceptuales y posibles solapamientos. La validez discriminante requiere una lectura integral, no una decisión mecánica basada en una sola tabla (Hair et al., 2021).

El criterio HTMT, sigla de Heterotrait-Monotrait Ratio, se ha consolidado como uno de los procedimientos más relevantes para evaluar validez discriminante en PLS-SEM. Su lógica consiste en comparar las correlaciones entre indicadores de constructos diferentes con las correlaciones entre indicadores del mismo constructo. Si dos constructos son realmente distintos, las relaciones entre indicadores de constructos diferentes no deberían ser excesivamente altas. Un valor HTMT elevado sugiere que los constructos podrían no estar suficientemente diferenciados. Como regla orientativa, suele considerarse que valores por debajo de **0.85** representan un criterio conservador, mientras que valores por debajo de **0.90** pueden aceptarse en contextos donde los constructos son conceptualmente cercanos. Sin embargo, estos umbrales no deben aplicarse sin razonamiento. Si dos constructos pertenecen a campos próximos, puede esperarse una relación mayor; pero si el valor se aproxima demasiado al límite o lo supera, debe revisarse si existe redundancia conceptual, indicadores ambiguos o una sobrefragmentación del fenómeno. El HTMT es valioso porque detecta problemas que otros criterios pueden pasar por alto, pero siempre debe interpretarse con fundamento teórico (Henseler et al., 2015).

Las **cargas cruzadas** constituyen un criterio complementario para evaluar si cada indicador se relaciona principalmente con el constructo al que pertenece. La lógica es directa: un indicador diseñado para medir **satisfacción** debería cargar más alto en satisfacción que en confianza, lealtad o compromiso. Si un indicador presenta una carga mayor en otro constructo, puede existir un problema de redacción, ubicación conceptual o especificación del modelo. Las cargas cruzadas permiten identificar ítems específicos que generan confusión, aunque no siempre son tan sensibles como HTMT para detectar problemas globales de discriminación. Su utilidad principal es diagnóstica: ayudan a localizar qué indicadores pueden estar causando solapamiento. Por ejemplo, un ítem como “confío en la empresa porque siempre cumple mis

expectativas" podría relacionarse tanto con confianza como con satisfacción si no está bien delimitado. En estos casos, el investigador debe decidir si el indicador debe permanecer, reformularse, moverse de constructo o eliminarse. Esta decisión no debe basarse solo en el número, sino en la coherencia conceptual del indicador dentro del modelo (Hair et al., 2021).

La falta de validez discriminante puede surgir por **redundancia conceptual**. Esto ocurre cuando dos constructos tienen nombres distintos, pero definiciones muy similares. Por ejemplo, si se define **capacidad digital** como el grado en que una organización usa tecnologías digitales para mejorar procesos, y **madurez digital** como el grado en que una organización integra tecnologías digitales en sus procesos, ambos constructos podrían solaparse si no se establecen diferencias claras. La redundancia también puede aparecer cuando los indicadores están redactados con vocabulario casi idéntico. En estos casos, los resultados empíricos pueden mostrar que los constructos no se distinguen, porque en realidad fueron construidos como versiones paralelas del mismo fenómeno. La solución no consiste simplemente en eliminar indicadores para mejorar el índice; primero debe revisarse si los constructos deberían mantenerse separados. Si la teoría no justifica su diferenciación, puede ser más adecuado fusionarlos o replantear la estructura conceptual. La validez discriminante, por tanto, funciona como una alerta sobre la calidad de la arquitectura teórica del modelo (Jarvis et al., 2003).

Otra causa frecuente de problemas discriminantes es la sobrefragmentación conceptual. Esta ocurre cuando el investigador divide un fenómeno amplio en demasiados constructos pequeños sin justificar suficientemente sus diferencias. Por ejemplo, en estudios de innovación o transformación digital, es común encontrar modelos con uso tecnológico, capacidad digital, competencia digital, madurez digital, adopción digital y transformación digital como constructos separados. Aunque cada término puede tener matices, si no se definen con rigor pueden terminar midiendo el mismo dominio. La sobrefragmentación genera modelos aparentemente sofisticados, pero empíricamente frágiles. Además, puede aumentar la complejidad sin aportar claridad teórica. En estos casos, la validez discriminante ayuda a detectar si la separación entre constructos es real o artificial. Un modelo más parsimonioso, con menos constructos pero mejor diferenciados, puede ser metodológicamente más fuerte que un modelo con muchas variables latentes solapadas. La pregunta clave es: **¿cada constructo aporta significado propio o solo repite una parte del mismo fenómeno?**. Esta pregunta debe responderse antes de defender las relaciones estructurales (Hair et al., 2021).

Los problemas de validez discriminante también pueden originarse en indicadores ambiguos. Un indicador ambiguo es aquel que podría pertenecer a más de un constructo porque su redacción no es específica. Por ejemplo, el ítem "la organización responde adecuadamente a las necesidades del cliente" podría estar asociado con orientación al mercado, calidad del servicio, satisfacción del cliente o capacidad de respuesta, dependiendo del modelo. Si el indicador no se ubica con claridad, puede generar cargas cruzadas o elevar el HTMT entre constructos. Para

evitar esto, cada indicador debe redactarse con un dominio conceptual preciso. El investigador debe preguntarse: **¿este ítem mide exclusivamente el constructo al que fue asignado o podría interpretarse como parte de otro?**. Si la respuesta es ambigua, el indicador debe ajustarse. La claridad semántica no solo mejora la comprensión del cuestionario, sino que protege la discriminación entre constructos. La validez discriminante se fortalece desde la redacción de los ítems, no únicamente desde el cálculo estadístico (Jarvis et al., 2003).

Cuando se detecta falta de validez discriminante, el investigador debe evitar soluciones puramente mecánicas. Una práctica incorrecta sería eliminar indicadores solo porque mejoran el HTMT o las cargas cruzadas, sin analizar su importancia conceptual. Si se elimina un indicador esencial, puede mejorar un índice, pero debilitar la validez de contenido del constructo. Por ello, la depuración debe seguir una secuencia cuidadosa. Primero, se revisa si el indicador está mal redactado o contiene doble significado. Segundo, se analiza si el indicador pertenece realmente al constructo asignado. Tercero, se evalúa si los constructos están bien diferenciados teóricamente. Cuarto, se decide si conviene reformular, eliminar, fusionar o conservar con justificación. En SEM, ajustar el modelo no debe significar perseguir números ideales, sino mejorar la correspondencia entre teoría y medición. La validez discriminante exige equilibrio entre evidencia empírica y juicio conceptual. Un modelo debe ser estadísticamente aceptable, pero también teóricamente defendible (Hair et al., 2021).

La validez discriminante tiene una función central en la interpretación del modelo estructural. Las relaciones entre constructos solo pueden interpretarse adecuadamente si los constructos son distintos. Por ejemplo, si confianza y satisfacción no se diferencian empíricamente, afirmar que la confianza influye en la satisfacción puede ser problemático, porque ambas variables podrían estar capturando la misma percepción global. Del mismo modo, si capacidad digital y transformación digital están fuertemente solapadas, sus efectos sobre desempeño innovador podrían confundirse. En SEM, cada flecha estructural presupone que los constructos conectados tienen identidad propia. Si esta condición no se cumple, los coeficientes *path* pueden perder significado sustantivo. Por ello, la validez discriminante debe evaluarse antes de interpretar relaciones directas, mediaciones, moderaciones o efectos totales. No se trata solo de validar una escala; se trata de asegurar que el modelo estructural se construye sobre entidades diferenciadas. Sin validez discriminante, la explicación estructural puede volverse circular o redundante (Henseler et al., 2015).

La validez discriminante también permite distinguir entre relación teórica legítima y solapamiento conceptual indebido. En ciencias de la administración, es normal que los constructos se relacionen entre sí. La satisfacción puede estar asociada con lealtad; la confianza con intención de uso; el aprendizaje con innovación; y la capacidad digital con desempeño. Una correlación alta no siempre significa problema. El problema aparece cuando la relación es tan elevada que los constructos parecen indistinguibles. La diferencia entre asociación y solapamiento es crucial. Dos

constructos pueden estar relacionados y aun así conservar identidad propia si sus definiciones, indicadores y funciones dentro del modelo son claras. Por ejemplo, satisfacción y lealtad pueden estar vinculadas, pero satisfacción refiere evaluación de experiencia, mientras lealtad refiere intención de continuidad o recomendación. La validez discriminante no busca aislar artificialmente los constructos, sino confirmar que cada uno aporta información propia. Esta distinción ayuda al investigador a interpretar resultados con mayor precisión (Hair et al., 2021).

La evaluación de validez discriminante debe integrarse en una lógica de calidad del modelo de medición. No debe analizarse aislada de la confiabilidad y la validez convergente. Un constructo puede mostrar alta consistencia interna, pero no diferenciarse de otros. También puede diferenciarse de otros, pero estar débilmente representado por sus indicadores. Por ello, la secuencia metodológica es progresiva: primero se revisa si los indicadores representan adecuadamente su constructo; después se evalúa si el constructo se distingue de los demás. Esta secuencia evita decisiones apresuradas. Por ejemplo, si un constructo tiene problemas de validez convergente, quizá sus indicadores están mal alineados; si además tiene problemas discriminantes, puede existir una falla más profunda en la definición conceptual. La evaluación del modelo de medición debe leerse como un sistema. La validez discriminante responde a una pregunta específica: **¿el constructo mide algo distinto de los otros constructos del modelo?**. Pero esta pregunta solo tiene sentido dentro de una evaluación integral (Hair et al., 2021).

La validez discriminante debe entenderse también como una defensa contra la interpretación inflada del modelo. Cuando dos constructos no se diferencian adecuadamente, el investigador puede creer que está evaluando relaciones entre fenómenos distintos, cuando en realidad está analizando variaciones de una misma entidad conceptual. Por ejemplo, si una escala de **satisfacción** incluye ítems de confianza y una escala de **confianza** incluye ítems de satisfacción, la relación entre ambas puede parecer fuerte, pero esa fuerza puede deberse a que los indicadores comparten contenido. En ese caso, el problema no es que el modelo haya descubierto una relación relevante, sino que las variables latentes fueron construidas sin separación suficiente. Por ello, la validez discriminante protege contra conclusiones exageradas. **Un modelo SEM no debe aparentar complejidad mediante constructos que empíricamente no se distinguen**. La discriminación entre constructos asegura que cada relación estructural tenga significado sustantivo y no sea producto de duplicidad conceptual (Henseler et al., 2015).

La interpretación del HTMT requiere prudencia metodológica. Aunque los valores menores a **0.85** suelen considerarse más estrictos y los menores a **0.90** más flexibles, el investigador debe decidir el umbral de acuerdo con la cercanía conceptual entre constructos. Si los constructos son muy distintos, conviene aplicar un criterio conservador. Si pertenecen al mismo dominio teórico, puede aceptarse un criterio menos estricto, siempre que exista justificación. Por ejemplo, satisfacción y lealtad pueden estar más asociadas que satisfacción y capacidad digital, pero aun así deben mantener identidad conceptual. El HTMT no debe interpretarse como una regla

aislada, sino como evidencia dentro de una evaluación mayor. **Un valor bajo apoya la diferenciación empírica; un valor alto obliga a revisar definiciones, indicadores y estructura del modelo**. Si se supera el umbral, no basta con eliminar ítems: primero debe analizarse si los constructos realmente merecen permanecer separados (Hair et al., 2021).

El criterio de Fornell-Larcker conserva utilidad como lectura complementaria, aunque no debe ser el único soporte de validez discriminante. Su lógica permite observar si cada constructo comparte más varianza con sus propios indicadores que con otros constructos. No obstante, puede fallar cuando los constructos están muy correlacionados o cuando el solapamiento es sutil. Por ello, su uso debe ser prudente. En un reporte académico, puede presentarse como evidencia adicional, pero no como prueba concluyente. **Cumplir Fornell-Larcker no garantiza por sí solo que los constructos estén plenamente diferenciados**. Del mismo modo, un incumplimiento debe interpretarse junto con la teoría y los demás resultados. Si Fornell-Larcker y HTMT coinciden en señalar problemas, el investigador tiene una alerta fuerte. Si divergen, conviene revisar cargas cruzadas, definiciones e indicadores específicos. La validez discriminante exige triangulación metodológica, no dependencia de una sola matriz (Hair et al., 2021).

Las cargas cruzadas ayudan a identificar si algún indicador está conceptualmente mal ubicado. Un indicador debería cargar más alto en su constructo asignado que en cualquier otro. Cuando esto no ocurre, el ítem puede estar redactado de forma ambigua, representar un constructo diferente o compartir demasiado contenido con otro dominio. Por ejemplo, un ítem sobre “cumplimiento de expectativas” podría relacionarse con satisfacción, confianza o calidad percibida, según el contexto. Si el indicador carga más alto en otro constructo, el investigador debe revisar si el problema está en el ítem o en la definición del constructo. Sin embargo, las cargas cruzadas no deben usarse de forma automática para eliminar indicadores. **La eliminación debe justificarse por razones conceptuales, no solo por conveniencia estadística**. Un indicador relevante puede requerir reformulación en estudios futuros, no necesariamente eliminación inmediata. La revisión de cargas cruzadas permite una depuración más fina del modelo de medición (Jarvis et al., 2003).

La falta de validez discriminante puede indicar que el modelo sufre falta de parsimonia. Cuando se incorporan demasiados constructos cercanos, el modelo puede parecer sofisticado, pero perder claridad. En administración, esto ocurre con frecuencia cuando se desea incluir múltiples variables de moda: transformación digital, madurez digital, capacidad digital, competencia digital, innovación digital y adopción tecnológica. Si cada constructo no tiene una función diferente, el modelo se sobrecarga. **La parsimonia no significa simplificar en exceso, sino conservar solo los constructos que aportan significado propio**. En algunos casos, una solución razonable puede ser fusionar constructos cercanos en uno más amplio; en otros, separar dimensiones con mayor precisión; y en otros, eliminar variables que no aportan al problema de investigación. La validez discriminante ayuda a decidir si el modelo

tiene demasiadas etiquetas para fenómenos que, empíricamente, se comportan como uno solo (Hair et al., 2021).

También debe distinguirse entre problemas de validez discriminante y problemas de teoría sustantiva. A veces, dos constructos muestran alta asociación porque la teoría predice una relación estrecha entre ellos. Por ejemplo, satisfacción y lealtad suelen relacionarse; confianza e intención de uso pueden estar fuertemente vinculadas; aprendizaje organizacional e innovación pueden compartir procesos. Esto no significa automáticamente que exista falta de discriminación. El problema aparece cuando los indicadores pierden especificidad y hacen que los constructos sean indistinguibles. Por ello, la interpretación debe responder dos preguntas: **¿la alta relación es teóricamente esperable?** y **¿los indicadores siguen representando dominios distintos?**. Si ambas respuestas son positivas, puede mantenerse la separación con argumentación sólida. Si la segunda respuesta es negativa, se requiere revisión. La validez discriminante no busca negar relaciones fuertes, sino asegurar que esas relaciones ocurren entre constructos diferentes (Henseler et al., 2015).

La validez discriminante también se vincula con la dimensionalidad del constructo. Cuando un constructo multidimensional se divide en varias dimensiones, es necesario comprobar que esas dimensiones sean distinguibles si se modelan por separado. Por ejemplo, en capacidad digital, infraestructura, habilidades digitales e integración de datos pueden ser dimensiones relacionadas, pero no necesariamente constructos independientes. Si se tratan como constructos separados, deben mostrar diferenciación conceptual y empírica. De lo contrario, podría ser más adecuado modelarlas como dimensiones de un constructo de orden superior o como componentes de un constructo compuesto. **La decisión entre dimensión, subconstructo o constructo independiente debe apoyarse en teoría y evidencia empírica**. La validez discriminante ayuda a determinar si la separación propuesta es defendible. Así, el análisis no solo evalúa ítems, sino también la arquitectura conceptual del modelo (Hair et al., 2021).

En modelos con constructos reflectivos, la validez discriminante tiene especial relevancia porque se espera que cada conjunto de indicadores represente una entidad latente diferente. Si dos constructos reflectivos no se distinguen, puede existir un problema en la definición de los dominios o en la selección de ítems. En cambio, en constructos formativos o compuestos, la lógica de evaluación cambia, porque los indicadores no necesariamente son manifestaciones intercambiables de una variable latente. Por ello, aunque el tema 5.3 se centra principalmente en la diferenciación entre constructos dentro del modelo de medición, conviene recordar que **los criterios como HTMT y Fornell-Larcker se interpretan principalmente en modelos reflectivos**. En constructos formativos o compuestos, la diferenciación conceptual, la colinealidad, la relevancia de los indicadores y la justificación teórica adquieren un papel más importante. Esta aclaración evita aplicar criterios reflectivos a estructuras que siguen otra lógica de medición (Hair et al., 2021).

La revisión de validez discriminante debe conectarse con la calidad del instrumento. Cuando se detectan valores problemáticos, no siempre significa que la

teoría esté equivocada; puede significar que la escala fue construida con indicadores demasiado parecidos o ambiguos. Por ejemplo, si un cuestionario usa repetidamente términos como “cumple expectativas”, “me genera confianza” y “me siento satisfecho” sin separar contextos, los constructos pueden contaminarse entre sí. La solución puede requerir mejorar la redacción, precisar el referente del ítem o separar mejor los dominios conceptuales. **La validez discriminante se gana desde el diseño del instrumento, no solo desde la depuración estadística posterior**. Por ello, los capítulos previos sobre concepto, constructo, dimensionalidad y escalas son esenciales para este tema. La evaluación empírica confirma si esa construcción previa fue suficientemente clara (Jarvis et al., 2003).

Al reportar la validez discriminante, conviene evitar frases demasiado genéricas como “se cumple la validez discriminante” sin explicación. Un reporte más sólido indica qué criterio se usó, qué umbral se adoptó y cómo se interpreta el resultado. Por ejemplo: “Los valores HTMT se ubicaron por debajo del umbral conservador de 0.85, lo que sugiere diferenciación empírica aceptable entre constructos”. Si se utiliza el umbral de 0.90, debe justificarse por cercanía conceptual. Si algún valor está cerca del límite, conviene explicarlo con prudencia. **Un buen reporte no solo presenta tablas, sino que explica qué significan los valores para la calidad del modelo de medición**. También puede señalar si la diferenciación estadística coincide con la diferenciación conceptual. Esta integración entre resultados y teoría fortalece la credibilidad del estudio (Henseler et al., 2015).

Cuando un valor HTMT supera el umbral adoptado, el investigador puede seguir una ruta de diagnóstico. Primero, revisar si los constructos tienen definiciones suficientemente distintas. Segundo, observar si los indicadores contienen lenguaje compartido o doble significado. Tercero, revisar cargas cruzadas para identificar ítems problemáticos. Cuarto, evaluar si la separación entre constructos está justificada por el problema de investigación. Quinto, decidir si se reformulan indicadores, se fusionan constructos o se conserva la estructura con justificación. **La corrección no debe ser automática; debe ser metodológicamente razonada**. El objetivo no es forzar el cumplimiento de un índice, sino mejorar la representación del fenómeno. En estudios de tesis o capítulos aplicados, esta ruta de diagnóstico ayuda a evitar decisiones improvisadas y permite defender por qué se conserva o modifica el modelo de medición (Hair et al., 2021).

La validez discriminante también tiene implicaciones para las hipótesis estructurales. Si dos constructos no se diferencian, una hipótesis que conecte ambos puede perder sentido. Por ejemplo, una hipótesis que proponga que la confianza influye en la satisfacción requiere que confianza y satisfacción sean constructos empíricamente distinguibles. Si no lo son, la hipótesis no está evaluando una relación entre fenómenos diferentes, sino una relación circular. Lo mismo ocurre con mediaciones: si el mediador no se diferencia del antecedente o de la variable dependiente, el mecanismo explicativo queda debilitado. **Toda hipótesis SEM presupone discriminación suficiente entre los constructos involucrados**. Por ello, la validez discriminante no es un requisito aislado del modelo de medición; es una

condición para interpretar hipótesis, efectos directos, indirectos y moderados con rigor (Hair et al., 2021).

En términos de enseñanza metodológica, la validez discriminante permite al investigador comprender que un modelo no mejora por multiplicar constructos, sino por diferenciarlos bien. Muchos modelos iniciales incluyen numerosas variables porque el investigador desea cubrir todo el fenómeno. Sin embargo, si esas variables no tienen fronteras claras, el modelo se vuelve confuso. La validez discriminante enseña a depurar la arquitectura conceptual: conservar lo necesario, distinguir lo relevante y eliminar lo redundante. Esta lógica fortalece la ortogonalidad entre constructos y evita que el modelo se convierta en un conjunto de sinónimos metodológicos. Un buen modelo SEM debe responder a una pregunta precisa con constructos conceptualmente diferenciados. **La calidad se encuentra en la distinción funcional de las variables, no en la cantidad de nombres incluidos** (Jarvis et al., 2003).

La validez discriminante debe interpretarse como parte de una secuencia creciente de evaluación. Primero, el investigador define constructos; después diseña indicadores; luego revisa confiabilidad y convergencia; posteriormente evalúa discriminación entre constructos; y finalmente interpreta relaciones estructurales. Alterar este orden puede generar conclusiones débiles. Si se interpretan coeficientes *path* antes de verificar que los constructos son distintos, se corre el riesgo de explicar relaciones inexistentes o redundantes. Por ello, el tema 5.3 ocupa un lugar estratégico en el capítulo: aparece después de la confiabilidad y antes de colinealidad, sesgo de método común y muestra. **La validez discriminante es el puente entre la calidad interna del constructo y la claridad del sistema de constructos** (Hair et al., 2021).

La validez discriminante debe cerrarse con una idea central: los constructos pueden estar relacionados, pero deben conservar identidad propia. La evaluación mediante HTMT, Fornell-Larcker y cargas cruzadas ofrece evidencia empírica sobre esa diferenciación, pero la interpretación final requiere teoría, claridad conceptual y revisión de indicadores. Valores orientativos como **HTMT < 0.85** o **HTMT < 0.90** ayudan a tomar decisiones, pero no sustituyen el juicio metodológico. Cuando la discriminación es adecuada, el modelo puede avanzar con mayor confianza hacia la evaluación de colinealidad, sesgo de método común y calidad general de los indicadores. Cuando no lo es, el investigador debe revisar el modelo antes de interpretar relaciones estructurales. En síntesis, **sin validez discriminante, no hay claridad suficiente para afirmar que el modelo analiza relaciones entre constructos distintos** (Henseler et al., 2015).

Colinealidad, sesgo de método común y calidad de los indicadores

La colinealidad, y específicamente la multicolinealidad, constituye el criterio técnico central para evaluar si dos o más indicadores o constructos explicativos

comparten demasiada información dentro del modelo. En PLS-SEM, esta revisión es indispensable porque una colinealidad elevada puede afectar la estabilidad de los pesos externos, la interpretación de los coeficientes *path* y la claridad del modelo. Cuando dos indicadores o predictores son casi equivalentes, el modelo puede tener dificultades para determinar cuál de ellos aporta realmente al constructo o a la variable dependiente. Por ejemplo, capacidad digital, madurez digital, uso tecnológico y transformación digital pueden solaparse si no fueron conceptualmente diferenciadas en etapas previas. En este sentido, la multicolinealidad no debe entenderse solo como un problema estadístico, sino como una posible señal de redundancia conceptual. El indicador más utilizado es el **VIF —Variance Inflation Factor**—, que permite revisar si un indicador o predictor está excesivamente asociado con otros. Como orientación, valores menores a 3.3 suelen considerarse conservadores, mientras que valores menores a 5.0 pueden aceptarse en ciertos estudios aplicados, siempre que exista justificación metodológica.

La multicolinealidad debe interpretarse en dos niveles complementarios. En el modelo de medición, permite revisar si los indicadores, especialmente en constructos formativos o compuestos, aportan contenido propio o si resultan redundantes entre sí. En el modelo estructural, permite verificar si varios constructos predictores de una misma variable dependiente compiten por explicar prácticamente el mismo contenido. Esta doble función justifica que su tratamiento técnico se concentre en este tema y no en capítulos anteriores. Los capítulos previos ayudan a prevenir redundancias desde la teoría, la pregunta, las hipótesis y la definición de constructos; el presente tema evalúa empíricamente si esa diferenciación conceptual se sostiene al revisar los datos (Diamantopoulos & Winklhofer, 2001; Kock, 2015).

El VIF cumple una función diagnóstica porque permite detectar si un indicador o predictor aporta información diferenciada o si repite contenido ya explicado por otros elementos del modelo. En constructos formativos y compuestos, esta revisión es especialmente relevante, porque los indicadores no son manifestaciones intercambiables del constructo, sino componentes que lo integran. Si esos componentes son demasiado similares, el constructo pierde claridad. Por ejemplo, una medición formativa de **capacidad digital** podría incluir infraestructura tecnológica, habilidades digitales, integración de datos y uso estratégico de herramientas. Cada componente aporta una parte distinta del constructo. Sin embargo, si se incorporan indicadores como “uso de tecnología digital”, “aplicación de herramientas digitales” y “empleo de recursos digitales” sin diferenciarlos, probablemente se está midiendo casi lo mismo. Un VIF elevado puede revelar esta repetición. La solución no debe ser automática; antes de eliminar un indicador, el investigador debe revisar si realmente es redundante o si representa una dimensión conceptualmente necesaria. Por ello, el VIF debe interpretarse junto con la teoría, la definición del constructo y el dominio conceptual de la medición (Diamantopoulos & Winklhofer, 2001).

La colinealidad también puede presentarse en el modelo estructural, cuando varios constructos explicativos predicen una misma variable dependiente. Por ejemplo, si un modelo incluye **cultura innovadora**, **orientación emprendedora**,

capacidad de innovación y **aprendizaje organizacional** como antecedentes del desempeño innovador, el investigador debe verificar si cada predictor aporta una explicación distinta. Si todos los constructos están altamente asociados, los coeficientes *path* pueden volverse inestables, cambiar de signo o perder significancia. Esto no significa que los constructos relacionados deban eliminarse automáticamente, porque en ciencias de la administración es normal que los fenómenos estén conectados. El problema aparece cuando los constructos no se distinguen lo suficiente y compiten por explicar el mismo contenido. La pregunta metodológica es: **¿cada predictor explica una parte diferente del resultado o todos representan el mismo fenómeno con nombres distintos?**. Cuando la colinealidad es baja o moderada, el modelo tiene mejores condiciones de interpretación; cuando es alta, conviene revisar definiciones, indicadores y estructura conceptual antes de interpretar efectos (Hair et al., 2019).

En términos aplicados, cuando dos indicadores presentan valores **VIF** superiores al criterio definido, **el investigador debe revisar si existe redundancia empírica y conceptual.** Si además los ítems expresan contenidos prácticamente equivalentes, como ocurre cuando dos reactivos solo reformulan una misma idea, la eliminación o reformulación del indicador con mayor VIF puede estar justificada. No obstante, la decisión debe confirmarse verificando que, después del ajuste, los valores VIF queden dentro del umbral adoptado y que no se pierda cobertura conceptual del constructo (Kock, 2015).

La colinealidad se relaciona directamente con la **parsimonia del modelo**. Un modelo parsimonioso no es un modelo simplista, sino uno que incluye los constructos necesarios para responder la pregunta de investigación sin duplicar explicaciones. En PLS-SEM, puede ser tentador incluir muchos antecedentes porque el método permite trabajar con modelos complejos. Sin embargo, la complejidad sin diferenciación conceptual puede producir colinealidad. Por ejemplo, agregar simultáneamente capacidad tecnológica, madurez digital, transformación digital, intensidad digital y uso de plataformas puede parecer sofisticado, pero si todos los indicadores capturan el mismo dominio, el modelo pierde precisión. La parsimonia exige preguntarse si cada constructo cumple una función propia. Si dos constructos explican prácticamente lo mismo, quizá uno debe eliminarse, fusionarse o redefinirse. En este sentido, el VIF funciona como una alerta metodológica: **no solo indica un problema numérico, sino una posible falta de economía conceptual**. La colinealidad invita a revisar si el modelo tiene más variables de las que realmente necesita para explicar el fenómeno (Hair et al., 2021).

En constructos formativos, la colinealidad tiene un peso metodológico mayor porque los indicadores forman el constructo y no necesariamente deben estar altamente correlacionados. A diferencia de los constructos reflectivos, donde la consistencia interna es esperada, en los formativos cada indicador debe aportar un componente específico y conceptualmente necesario. Por ello, antes de interpretar pesos externos, debe revisarse si los indicadores presentan niveles aceptables de VIF. Un criterio conservador es mantener valores iguales o inferiores a 3.3, aunque algunos

reportes aplican umbrales más estrictos cuando el modelo exige mayor diferenciación entre componentes. La decisión final no debe basarse solo en el umbral, sino en la convergencia entre VIF, peso externo, carga, significación y relevancia conceptual del indicador (Diamantopoulos & Winklhofer, 2001). Por ejemplo, para medir una **capacidad organizacional**, pueden incluirse recursos humanos, infraestructura, procesos, conocimiento y coordinación. Estos componentes no tienen por qué ser equivalentes ni moverse en la misma dirección. Por ello, una alta colinealidad entre indicadores formativos puede indicar que dos componentes están capturando la misma parte del constructo. Esto afecta la interpretación de los **pesos externos**, porque el modelo puede no identificar con claridad qué indicador contribuye de forma única. En estos casos, el investigador debe revisar si los indicadores son conceptualmente diferentes. Si no lo son, puede ser conveniente fusionarlos o reformularlos. Si sí lo son, puede conservarlos con justificación, aunque siempre atendiendo los niveles de VIF y su efecto en la estabilidad del modelo (Diamantopoulos & Winklhofer, 2001).

La colinealidad también puede afectar la interpretación de los pesos externos en constructos formativos y compuestos. Cuando dos indicadores formativos están altamente relacionados, uno puede aparecer con peso bajo o no significativo, aunque conceptualmente sea importante. Esto puede ocurrir no porque el indicador sea irrelevante, sino porque comparte demasiada información con otro. Por ejemplo, si "competencia digital" y "habilidad digital" se incluyen como componentes separados, uno puede absorber el efecto del otro. En ese caso, eliminar el indicador no siempre es la mejor solución. Primero debe evaluarse si ambos representan dimensiones distintas o si uno es simplemente una reformulación del otro. Si son redundantes, se justifica la eliminación o fusión. Si son conceptualmente necesarios, puede conservarse el indicador y explicar su función teórica. Esta lectura evita decisiones mecánicas basadas solo en significancia. En PLS-SEM, los formativos requieren una evaluación donde **peso estadístico, colinealidad y relevancia conceptual** se interpreten de manera conjunta (Hair et al., 2021).

El **sesgo de método común** aparece cuando las relaciones entre variables pueden estar infladas por la forma en que se recolectaron los datos, más que por relaciones sustantivas entre los fenómenos. Este riesgo es frecuente en investigaciones administrativas basadas en encuestas, especialmente cuando todas las variables se miden con el mismo instrumento, en el mismo momento, con el mismo tipo de escala y a partir del mismo informante. Por ejemplo, si un directivo responde en una sola encuesta sobre cultura innovadora, capacidades digitales, aprendizaje organizacional y desempeño, parte de las asociaciones observadas puede deberse al estilo de respuesta, deseabilidad social, consistencia artificial o tendencia a responder positivamente. El sesgo de método común no invalida automáticamente un estudio, pero sí exige prevención, diagnóstico e interpretación prudente. Su importancia radica en que puede hacer que las relaciones estructurales parezcan más fuertes de lo que realmente son. Por ello, el investigador debe reconocer este riesgo desde el diseño y no únicamente cuando ya tiene los resultados (Podsakoff et al., 2024).

Las estrategias para reducir el sesgo de método común deben comenzar antes de la recolección de datos. Entre las medidas preventivas se encuentran: garantizar anonimato, redactar ítems claros, evitar preguntas con carga moral, separar psicológicamente las secciones del cuestionario, variar formatos de respuesta cuando sea pertinente y reducir ambigüedad en los indicadores. También puede ser útil recolectar datos de distintas fuentes: por ejemplo, medir capacidades organizacionales con directivos y desempeño con registros objetivos o datos secundarios. Cuando no es posible usar múltiples fuentes, al menos debe cuidarse el diseño del instrumento para reducir respuestas automáticas o socialmente deseables. Estas medidas son importantes porque el sesgo de método común es difícil de corregir después de recolectar los datos. En estudios PLS-SEM, donde es común trabajar con cuestionarios autoinformados, la prevención fortalece la credibilidad del análisis. **La mejor defensa contra el sesgo común no es solo estadística; es un diseño cuidadoso del instrumento y del procedimiento de medición** (Podsakoff et al., 2024).

Una aproximación utilizada en PLS-SEM para diagnosticar el sesgo de método común es la **evaluación de colinealidad completa**, conocida como ***full collinearity assessment***. Esta técnica consiste en revisar los valores VIF considerando cada constructo como variable dependiente frente a los demás, con el objetivo de detectar colinealidad generalizada que podría sugerir sesgo de método común. Como criterio orientativo, valores VIF menores a **3.3** suelen interpretarse como señal de que el sesgo de método común no representa una amenaza severa. Sin embargo, este criterio debe aplicarse con prudencia. Un VIF bajo no elimina completamente el riesgo de sesgo, así como un valor elevado no siempre prueba su existencia de forma definitiva. El ***full collinearity assessment*** debe entenderse como una herramienta diagnóstica complementaria, no como una garantía absoluta. Su valor metodológico aumenta cuando se combina con medidas preventivas, revisión conceptual del instrumento y análisis crítico de la fuente de datos. Así, el investigador evita convertir un criterio útil en una regla mecánica (Kock, 2015).

En una aplicación operativa, el ***full collinearity assessment*** permite revisar si existe colinealidad generalizada entre las variables latentes del modelo y, por extensión, si puede haber señales de contaminación por método común. El procedimiento puede realizarse modelando los constructos como predictores y examinando los valores **VIF** resultantes. Cuando los VIF superan el umbral conservador de **3.3**, el resultado puede sugerir una posible amenaza metodológica. Sin embargo, este valor no debe interpretarse como prueba automática de sesgo, porque un VIF elevado también puede revelar **redundancia conceptual**, **indicadores mal asignados**, **constructos excesivamente similares** o una arquitectura del modelo demasiado fragmentada. En consecuencia, si aparecen valores problemáticos, el investigador debe revisar si conviene eliminar indicadores, reasignarlos, combinar constructos o reformular la especificación conceptual. La utilidad de esta prueba no está solo en detectar un problema estadístico, sino en obligar a revisar si el instrumento y el modelo distinguen adecuadamente los constructos que dicen medir (Kock & Lynn, 2012).

La calidad de los indicadores constituye el tercer eje de este tema. Un indicador de calidad no es solo aquel que cumple umbrales estadísticos; también debe representar adecuadamente el constructo. En modelos reflectivos, los indicadores deben reflejar manifestaciones coherentes de la entidad latente. En modelos formativos o compuestos, cada indicador debe aportar una parte relevante y no redundante del dominio conceptual. Por ello, la depuración de indicadores no debe hacerse únicamente para mejorar cifras. Eliminar un ítem puede elevar una métrica, pero debilitar la cobertura conceptual del constructo. Antes de tomar decisiones, el investigador debe preguntarse: **¿este indicador aporta contenido propio?, ¿es comprensible para el informante?, ¿corresponde al constructo?, ¿su eliminación afectaría el significado teórico?, ¿está generando colinealidad o ambigüedad?**. La calidad del indicador surge de la intersección entre teoría, redacción, evidencia empírica y función dentro del modelo. Un indicador estadísticamente aceptable pero conceptualmente débil sigue siendo problemático (Jarvis et al., 2003).

La calidad de los indicadores también debe evaluarse desde su claridad semántica. Un indicador ambiguo puede generar colinealidad, problemas discriminantes y respuestas inconsistentes. Por ejemplo, un ítem como “la empresa utiliza adecuadamente herramientas digitales para mejorar el desempeño” puede interpretarse como capacidad digital, desempeño organizacional o transformación digital. Cuando un indicador contiene múltiples ideas o términos demasiado amplios, el participante puede responder desde interpretaciones diferentes, afectando la calidad de la medición. Por ello, cada indicador debe expresar una sola idea central y corresponder claramente al constructo al que pertenece. Además, debe ser comprensible para la población estudiada. Un ítem técnicamente sofisticado pero difícil de entender puede generar ruido estadístico y reducir la calidad del modelo. **La claridad del indicador no es un aspecto estético; es una condición metodológica de validez y estabilidad**. La evaluación de indicadores debe considerar tanto su función estadística como su precisión lingüística (Jarvis et al., 2003).

La colinealidad también puede aparecer como consecuencia de una mala delimitación de dimensiones. Cuando un constructo multidimensional se divide en varias partes demasiado similares, las dimensiones pueden terminar explicando prácticamente lo mismo. Por ejemplo, un modelo de innovación podría separar “innovación tecnológica”, “innovación digital” e “innovación basada en tecnología”, aunque conceptualmente representen dominios muy cercanos. Esta fragmentación artificial incrementa el riesgo de colinealidad y dificulta la interpretación estructural. En estos casos, el investigador debe revisar si realmente existen diferencias sustantivas entre dimensiones o si conviene integrarlas dentro de un constructo más amplio. La colinealidad funciona aquí como una señal de alerta sobre la arquitectura conceptual del modelo. **Un modelo más complejo no necesariamente es un mejor modelo; la complejidad solo aporta valor cuando cada dimensión añade significado propio** (Hair et al., 2021).

Otro aspecto importante es que la colinealidad puede afectar la estabilidad de los coeficientes *path*. Cuando varios constructos explicativos están altamente

correlacionados, los coeficientes pueden cambiar drásticamente si se agrega o elimina una variable. Por ejemplo, capacidad digital puede mostrar un efecto positivo fuerte sobre innovación cuando se analiza sola, pero perder significancia cuando se incorpora transformación digital altamente correlacionada. Esto no siempre significa que el constructo sea irrelevante; puede indicar que ambos están compitiendo por explicar la misma varianza. En consecuencia, la interpretación de los coeficientes debe considerar si el modelo presenta niveles aceptables de colinealidad. **Un coeficiente no significativo en presencia de alta colinealidad no necesariamente implica ausencia de efecto conceptual**. Por ello, la lectura de resultados estructurales debe integrar VIF, teoría y función de cada constructo dentro del sistema (Hair et al., 2019).

El sesgo de método común puede adoptar distintas formas. Una de ellas es la **deseabilidad social**, donde el participante responde de manera que considera socialmente aceptable en lugar de expresar su percepción real. Otra es la **consistencia artificial**, donde el encuestado intenta mantener coherencia entre respuestas aunque las preguntas midan fenómenos distintos. También puede aparecer el **sesgo de aquiescencia**, cuando el participante tiende a estar de acuerdo con la mayoría de los ítems independientemente de su contenido. Estos efectos pueden inflar correlaciones y producir relaciones estructurales aparentemente fuertes. Por ello, el investigador debe reconocer que la calidad de los datos depende no solo del modelo, sino también del comportamiento del informante. Las estrategias preventivas ayudan a reducir estos riesgos, pero nunca los eliminan completamente. En consecuencia, los resultados deben interpretarse con prudencia y reconocer posibles limitaciones derivadas de la fuente de información (Podsakoff et al., 2024).

En investigaciones administrativas, el sesgo de método común es especialmente relevante porque muchas variables se miden mediante percepciones subjetivas. Cultura organizacional, satisfacción, confianza, aprendizaje, innovación o liderazgo suelen capturarse a través de cuestionarios. Esto no invalida su estudio, pero obliga a fortalecer el diseño metodológico. Una práctica recomendable es separar conceptualmente las secciones del instrumento para evitar que el participante responda todas las preguntas bajo la misma lógica psicológica. También puede ser útil alternar formulaciones positivas y negativas cuando sea metodológicamente pertinente, aunque esto debe hacerse con cuidado para no generar confusión. El objetivo es reducir la probabilidad de respuestas automáticas. **La calidad de un modelo SEM depende tanto de la estructura estadística como de la calidad cognitiva del proceso de respuesta** (Podsakoff et al., 2024).

La evaluación de calidad de indicadores también implica revisar su pertinencia contextual. Un indicador puede funcionar adecuadamente en un contexto y resultar inapropiado en otro. Por ejemplo, indicadores sobre transformación digital diseñados para grandes corporaciones pueden no ser adecuados para microempresas o instituciones públicas. Del mismo modo, un lenguaje técnico puede ser comprensible para especialistas en tecnología, pero no para usuarios generales. La calidad del indicador depende de que el informante pueda responderlo desde su experiencia real. Por ello, antes de aplicar el instrumento, conviene revisar si los ítems son pertinentes

para el contexto, sector y unidad de análisis. **Un indicador estadísticamente sólido pero contextualmente irrelevante sigue siendo metodológicamente débil**. La pertinencia contextual fortalece la validez de contenido y reduce errores derivados de interpretación ambigua (Hair et al., 2021).

La colinealidad también puede analizarse desde una perspectiva de economía conceptual. En ocasiones, el investigador incorpora múltiples variables porque desea mostrar un modelo amplio, pero termina incluyendo constructos redundantes. Por ejemplo, un estudio sobre desempeño organizacional puede incluir satisfacción laboral, compromiso organizacional, motivación y bienestar psicológico sin distinguir claramente sus funciones. Aunque todos sean relevantes, deben tener un papel específico dentro del modelo. Si varios constructos explican prácticamente el mismo fenómeno, el modelo se vuelve innecesariamente complejo. El análisis de VIF ayuda a detectar esta situación. **La economía conceptual no significa reducir variables arbitrariamente, sino conservar solo aquellas que aportan valor explicativo real**. Esta lógica mejora la claridad del modelo y facilita su interpretación posterior (Hair et al., 2021).

En modelos formativos y compuestos, la calidad de los indicadores debe evaluarse también mediante su relevancia conceptual. Un indicador puede mostrar bajo peso estadístico y aun así ser importante teóricamente. Por ejemplo, dentro de una capacidad digital organizacional, un indicador sobre ciberseguridad puede no ser dominante en términos estadísticos, pero seguir siendo esencial conceptualmente. En estos casos, eliminarlo únicamente para mejorar pesos o significancia podría empobrecer el constructo. La decisión debe equilibrar evidencia empírica y fundamento teórico. Los modelos formativos requieren esta flexibilidad porque los indicadores no son necesariamente intercambiables. **La relevancia conceptual puede justificar la permanencia de indicadores que no destacan estadísticamente, siempre que su aporte teórico sea claro** (Diamantopoulos & Winklhofer, 2001).

La relación entre multicolinealidad y sesgo de método común es importante porque ambos fenómenos pueden inflar asociaciones dentro del modelo. Si todos los constructos están altamente correlacionados debido al método de medición, el VIF puede aumentar y sugerir colinealidad generalizada. Por ello, la evaluación de colinealidad completa, o full collinearity assessment, puede utilizarse como aproximación diagnóstica indirecta para detectar posible sesgo de método común. Sin embargo, esta estrategia no debe interpretarse como prueba definitiva. La ausencia de VIF elevados no garantiza automáticamente ausencia de sesgo, así como valores altos pueden deberse también a proximidad conceptual legítima entre constructos. El investigador debe integrar múltiples fuentes de evidencia: diseño del instrumento, tipo de informante, estructura conceptual, HTMT, VIF y revisión crítica de los datos. La evaluación metodológica en SEM no funciona mediante un único índice universal, sino mediante convergencia de criterios (Kock, 2015).

La calidad de los indicadores también influye en la **potencia explicativa y predictiva del modelo**. Indicadores ambiguos, redundantes o mal contextualizados pueden reducir la capacidad del modelo para representar adecuadamente los

constructos. Esto afecta no solo la medición, sino también las relaciones estructurales posteriores. Por ejemplo, un constructo de innovación medido con indicadores débiles puede generar coeficientes inconsistentes y baja capacidad predictiva. En cambio, indicadores claros y conceptualmente alineados fortalecen la estabilidad del modelo. **La calidad del análisis estructural depende directamente de la calidad de los indicadores que alimentan el modelo de medición**. Por ello, este tema no debe entenderse como un apartado técnico aislado, sino como parte de la construcción integral del modelo SEM (Hair et al., 2021).

La evaluación de colinealidad y sesgo común debe reportarse de forma transparente. No basta con mencionar que "los VIF fueron aceptables"; conviene indicar el criterio adoptado y el rango observado. Por ejemplo: "Los valores VIF se ubicaron por debajo de 3.3, lo que sugiere ausencia de problemas severos de colinealidad y reduce la probabilidad de sesgo de método común". Si algún indicador presenta VIF elevado, debe discutirse. También es recomendable explicar qué estrategias preventivas se utilizaron durante el diseño del cuestionario. **La transparencia metodológica fortalece la credibilidad del estudio y demuestra control sobre posibles amenazas de validez** (Kock, 2015).

Desde una perspectiva pedagógica, el tema enseña que un modelo SEM no debe evaluarse únicamente por índices de ajuste o significancia. Antes de interpretar relaciones estructurales, el investigador debe asegurarse de que los indicadores sean claros, pertinentes y no redundantes; de que los constructos estén suficientemente diferenciados; y de que las relaciones observadas no estén infladas por el método de recolección de datos. Esta revisión prepara el terreno para el siguiente tema sobre tamaño de muestra y potencia estadística. **Un modelo conceptualmente redundante o sesgado difícilmente podrá sostener interpretaciones robustas, aunque la muestra sea grande o los coeficientes sean significativos** (Hair et al., 2021).

En síntesis, la colinealidad permite detectar redundancia entre indicadores y constructos; el **sesgo de método común** alerta sobre relaciones infladas por el procedimiento de medición; y la **calidad de los indicadores** garantiza que cada ítem represente adecuadamente el dominio conceptual del constructo. El **VIF** constituye el criterio central para evaluar colinealidad, con valores orientativos menores a **3.3** como referencia conservadora y menores a **5.0** en ciertos contextos aplicados. En cuanto al sesgo de método común, el **full collinearity assessment** ofrece evidencia diagnóstica adicional, especialmente cuando los VIF se mantienen bajos. Sin embargo, ningún índice debe interpretarse de forma aislada. La evaluación debe integrar teoría, diseño del instrumento, tipo de constructo y propósito del estudio. Así, el investigador fortalece la estabilidad conceptual y empírica del modelo antes de avanzar hacia la revisión de tamaño de muestra, potencia estadística y capacidad analítica del sistema SEM (Podsakoff et al., 2024).

Tamaño de muestra, potencia estadística y viabilidad del modelo

El **tamaño de muestra** y la **potencia estadística** determinan si el modelo PLS-SEM tiene condiciones suficientes para estimar relaciones con estabilidad y detectar efectos relevantes. Después de revisar confiabilidad, validez convergente, validez discriminante, colinealidad, sesgo de método común y calidad de indicadores, el investigador debe preguntarse si la cantidad de datos disponibles es proporcional a la complejidad del modelo. Un modelo con muchos constructos, indicadores, rutas, mediaciones o moderaciones exige mayor soporte empírico que un modelo simple. Por ello, la muestra no debe definirse únicamente por conveniencia o disponibilidad, sino por la capacidad del estudio para sostener las relaciones propuestas. En PLS-SEM, esta reflexión es especialmente importante porque el método suele aplicarse en modelos complejos y orientados a explicación-predicción. Sin embargo, su flexibilidad no significa que cualquier tamaño muestral sea suficiente. **Una muestra insuficiente puede producir estimaciones inestables, baja capacidad para detectar efectos reales y conclusiones metodológicamente débiles**. La pregunta central no es solo cuántos casos se tienen, sino si esos casos son suficientes para el modelo que se desea estimar (Hair et al., 2021).

La **potencia estadística** se refiere a la probabilidad de detectar un efecto real cuando dicho efecto existe. En términos sencillos, un estudio con potencia insuficiente puede concluir que una relación no es significativa aunque en realidad exista en la población. Esto se conoce como error tipo II. La potencia depende principalmente del tamaño de muestra, del tamaño esperado del efecto, del nivel de significancia y de la complejidad del modelo. Por ejemplo, detectar un efecto grande requiere menos casos que detectar un efecto pequeño. En administración, muchas relaciones entre constructos pueden ser moderadas o pequeñas, especialmente cuando se trabaja con fenómenos complejos como innovación, desempeño, satisfacción o adopción tecnológica. Por ello, el investigador debe evitar asumir que una muestra “grande en apariencia” siempre es suficiente. **La muestra debe evaluarse en función del efecto que se espera detectar y de la estructura del modelo**, no solo por el número absoluto de observaciones. La potencia estadística permite pasar de una lógica de disponibilidad de datos a una lógica de suficiencia analítica (Cohen, 1992).

La conocida **regla de 10 veces** ha sido utilizada durante años como orientación inicial en PLS-SEM. Esta regla sugiere que el tamaño mínimo de muestra debe ser al menos diez veces el mayor número de rutas estructurales que apuntan a un constructo dependiente, o diez veces el mayor número de indicadores formativos asociados a un constructo. Por ejemplo, si un constructo recibe cinco rutas de variables antecedentes, la regla sugeriría al menos cincuenta casos. Sin embargo, aunque esta regla puede ser útil como punto de partida pedagógico, actualmente se considera limitada porque no toma en cuenta el tamaño del efecto, el nivel de significancia, la potencia deseada ni la complejidad real del modelo. **La regla de 10 veces no debe utilizarse como único criterio para justificar una muestra**, especialmente en trabajos de

investigación doctoral o artículos académicos. Su valor es introductorio, no definitivo. El investigador puede mencionarla como referencia mínima preliminar, pero debe complementarla con métodos más robustos de estimación del tamaño muestral (Hair et al., 2021).

Un enfoque más sólido consiste en estimar el tamaño de muestra considerando potencia estadística, nivel de significancia y tamaño del efecto esperado. En estudios cuantitativos, es común trabajar con una potencia mínima de **0.80**, lo que implica una **probabilidad del 80%** de detectar un efecto real si existe. También suele utilizarse un nivel de significancia de **0.05**, aunque puede variar según el campo y el diseño. El tamaño del efecto puede clasificarse de manera orientativa como pequeño, mediano o grande. En modelos estructurales, esta clasificación ayuda a decidir cuántos casos se requieren para detectar relaciones de determinada magnitud. Un modelo que espera efectos pequeños necesitará más casos; uno que espera efectos grandes puede requerir menos. Por ello, **el cálculo muestral debe responder al efecto más difícil de detectar dentro del modelo**, no solamente a la ruta principal más evidente. Esta lógica es especialmente relevante cuando se incluyen mediadores, moderadores o relaciones indirectas, porque estos efectos suelen requerir mayor soporte empírico (Cohen, 1992).

En PLS-SEM, el tamaño de muestra también debe relacionarse con la **complejidad del modelo estructural**. Un modelo con pocas rutas directas puede estimarse con menor muestra que uno con múltiples antecedentes, mediaciones, moderaciones y constructos de orden superior. La complejidad no se mide solo por el número total de constructos, sino por la cantidad de relaciones que deben estimarse y por el número de predictores que apuntan simultáneamente a una variable endógena. Por ejemplo, un modelo con ocho constructos puede ser manejable si las relaciones están distribuidas de manera simple; pero un modelo con cinco constructos puede ser exigente si una variable dependiente recibe muchos predictores. Además, las moderaciones incrementan la complejidad porque implican efectos de interacción. **La viabilidad estadística del modelo depende de la relación entre muestra disponible y carga analítica del sistema estructural**. Por ello, antes de recolectar datos, el investigador debe revisar si su modelo es proporcional al tamaño de muestra que puede obtener (Hair et al., 2019).

La **regresión múltiple** ofrece una referencia útil para comprender por qué el número de predictores afecta el tamaño de muestra. Cuando una variable dependiente recibe varios antecedentes, el modelo necesita suficientes casos para estimar el aporte específico de cada predictor. Si se incluyen muchos predictores con una muestra pequeña, se reduce la estabilidad de las estimaciones. En investigación administrativa, esto ocurre cuando se intenta explicar desempeño, innovación o satisfacción mediante una lista extensa de antecedentes. Aunque cada predictor pueda estar teóricamente justificado, el modelo puede perder viabilidad si la muestra no sostiene esa complejidad. Por ello, los criterios de tamaño muestral deben considerar el número de predictores y la magnitud esperada de los efectos. **La inclusión de variables explicativas debe equilibrar pertinencia teórica y capacidad estadística**

disponible. Un modelo parsimonioso puede ser más robusto que uno sobrecargado con una muestra insuficiente. La muestra no solo limita el análisis; también orienta decisiones de diseño (Green, 1991).

En PLS-SEM, Kock y Hadaya propusieron métodos específicos para estimar tamaño mínimo de muestra, como el **inverse square root method** y el **gamma-exponential method**. Estos métodos buscan ofrecer una alternativa más precisa que la regla de 10 veces, considerando la magnitud mínima del coeficiente *path* que se desea detectar, el nivel de significancia y la potencia estadística. Su utilidad radica en que permiten pensar la muestra de manera más alineada con la capacidad real del modelo para identificar relaciones. Por ejemplo, si se espera detectar coeficientes pequeños, el tamaño muestral requerido será mayor. Si se esperan coeficientes medianos o grandes, el requerimiento puede ser menor. **Estos métodos son especialmente relevantes para PLS-SEM porque se enfocan en la detección de relaciones estructurales dentro de modelos basados en varianza**. Aunque pueden requerir mayor familiaridad técnica, ofrecen una justificación más sólida para tesis, artículos y reportes metodológicos avanzados (Kock & Hadaya, 2018).

La viabilidad del modelo también depende del tipo de constructos incluidos. Los constructos reflectivos, formativos y compuestos tienen exigencias distintas. En constructos reflectivos, la calidad de la medición se apoya en cargas, confiabilidad, AVE y validez discriminante. En constructos formativos, la evaluación requiere atender pesos, relevancia conceptual y colinealidad. Si un modelo combina constructos reflectivos, formativos y compuestos, su complejidad aumenta. Además, los constructos con muchos indicadores incrementan la carga de estimación y pueden exigir muestras mayores para obtener resultados estables. Esto no significa que deban evitarse modelos complejos, sino que la muestra debe estar alineada con esa complejidad. **Un modelo con múltiples constructos y muchos indicadores necesita una base empírica suficientemente amplia para evitar conclusiones frágiles**. Por ello, el tamaño de muestra no debe decidirse al final, sino desde el diseño conceptual y de medición del estudio (Hair et al., 2021).

La muestra también debe evaluarse en relación con la calidad de los datos. Una muestra numerosa no garantiza resultados válidos si los datos contienen respuestas descuidadas, patrones automáticos, valores faltantes excesivos o informantes no pertinentes. Por ejemplo, 500 cuestionarios con baja calidad pueden ser menos útiles que 250 respuestas cuidadosamente recolectadas con informantes adecuados. La potencia estadística requiere casos suficientes, pero también datos confiables. En estudios administrativos, es frecuente recolectar datos mediante encuestas en línea; esto facilita ampliar la muestra, pero puede aumentar riesgos de respuestas rápidas, duplicadas o poco reflexivas. Por ello, antes de estimar el modelo, el investigador debe revisar consistencia de respuestas, tiempos de contestación, datos faltantes, patrones extremos y pertinencia de los informantes. **El tamaño de muestra debe entenderse junto con la calidad muestral**, porque la cantidad sin calidad puede producir una falsa sensación de robustez metodológica (Hair et al., 2021).

El diseño muestral debe mantener coherencia con la unidad de análisis. Si el modelo estudia individuos, cada caso debe representar una persona; si estudia empresas, cada caso debe representar una organización; si estudia equipos, cada caso debe representar un grupo. Este punto es fundamental porque el número de respuestas no siempre equivale al número de unidades analíticas válidas. Por ejemplo, si se estudian empresas y se obtienen tres respuestas por empresa, no se tienen tres empresas, sino tres informantes dentro de una misma unidad organizacional. Si no se justifica la agregación, se puede inflar artificialmente el tamaño de muestra. De igual manera, si se estudian estudiantes, consumidores o empleados, las respuestas individuales pueden ser adecuadas, siempre que el constructo esté definido a ese nivel. **La suficiencia muestral solo tiene sentido cuando los casos corresponden correctamente a la unidad de análisis del modelo**. Por ello, el investigador debe aclarar qué representa cada observación antes de justificar el tamaño de muestra (Green, 1991).

La potencia estadística debe entenderse también como una condición para interpretar adecuadamente los resultados no significativos. Cuando un modelo tiene baja potencia, una relación puede aparecer como no significativa simplemente porque el estudio no tuvo suficientes casos para detectarla. Esto es particularmente importante en efectos pequeños, mediaciones y moderaciones, donde la magnitud del efecto suele ser menor. Por ejemplo, una moderación entre turbulencia ambiental y capacidades digitales puede ser conceptualmente relevante, pero difícil de detectar con muestras reducidas. En estos casos, concluir apresuradamente que “no existe relación” sería metodológicamente riesgoso. El investigador debe preguntarse si el modelo realmente tuvo capacidad para detectar ese efecto. **Una relación no significativa en un estudio con potencia insuficiente no necesariamente implica ausencia de efecto en la población**. Por ello, el análisis de potencia ayuda a interpretar tanto relaciones significativas como no significativas, fortaleciendo la prudencia metodológica del estudio (Cohen, 1992).

En modelos PLS-SEM, las mediaciones suelen requerir muestras mayores porque implican efectos indirectos. Un efecto indirecto depende de la combinación de dos o más relaciones estructurales. Por ejemplo, si capacidades digitales influyen en desempeño innovador a través de aprendizaje organizacional, el efecto mediado depende tanto de la relación entre capacidades digitales y aprendizaje como de la relación entre aprendizaje y desempeño. Aunque cada efecto individual sea moderado, el efecto indirecto total puede ser pequeño. Detectar este tipo de relaciones requiere suficiente potencia estadística. Lo mismo ocurre con las moderaciones, donde los términos de interacción incrementan la complejidad del modelo. **Cuanto mayor es la sofisticación estructural del modelo, mayor suele ser la exigencia muestral**. Por ello, antes de incorporar múltiples mediadores y moderadores, el investigador debe evaluar si realmente dispone de la muestra necesaria para sostener esa complejidad analítica (Hair et al., 2021).

La viabilidad del modelo también depende del equilibrio entre teoría y factibilidad empírica. En investigación administrativa, es común que el investigador

desee incluir muchos constructos porque todos parecen relevantes. Sin embargo, un modelo demasiado ambicioso puede volverse metodológicamente inviable si la muestra disponible es limitada. Por ejemplo, un estudiante doctoral puede diseñar un modelo con doce constructos, múltiples moderaciones y constructos de segundo orden, pero solo tener acceso a cien respuestas. Aunque el modelo sea conceptualmente interesante, la capacidad empírica para estimarlo será reducida. En estos casos, la solución no siempre consiste en buscar más datos; también puede requerir simplificar el modelo, priorizar relaciones centrales o dividir el estudio en fases. **La viabilidad metodológica implica construir un modelo proporcional a la capacidad real de recolección de datos**. Esta reflexión es una forma de rigor, no una limitación de la creatividad investigativa (Hair et al., 2019).

El tamaño de muestra debe analizarse también desde la perspectiva de la heterogeneidad de la población. Una muestra puede ser suficiente en cantidad, pero insuficiente si la población es demasiado diversa y el modelo pretende generalizar resultados amplios. Por ejemplo, un estudio sobre transformación digital puede incluir empresas manufactureras, comerciales, tecnológicas y de servicios. Aunque el número total de casos sea alto, las diferencias entre sectores pueden afectar la estabilidad de las relaciones estructurales. Lo mismo ocurre con estudios que mezclan estudiantes de licenciatura y posgrado, empresas pequeñas y grandes, o instituciones públicas y privadas. En estos casos, el investigador debe decidir si conviene trabajar con análisis multigrupo, segmentar la muestra o delimitar mejor el contexto. **La suficiencia muestral no depende únicamente del número de casos, sino también de la homogeneidad o diversidad de la población estudiada** (Hair et al., 2021).

En PLS-SEM, la muestra adquiere relevancia especial porque el método está orientado a **maximizar la varianza explicada** de los constructos dependientes. Esto significa que la estabilidad de los coeficientes *path*, los valores R^2 y las capacidades predictivas dependen de la calidad y suficiencia de los datos. Una muestra pequeña puede generar fluctuaciones importantes en las estimaciones, especialmente cuando se utilizan procedimientos de remuestreo como ***bootstrapping***. El *bootstrapping* crea múltiples submuestras para estimar errores estándar, intervalos de confianza y significancia. Si la muestra original es limitada, las estimaciones pueden volverse menos estables. Por ello, la potencia estadística y el tamaño de muestra no solo afectan la detección de efectos, sino también la robustez de los procedimientos de inferencia utilizados en PLS-SEM. **La estabilidad del modelo depende directamente de la estabilidad de la muestra que alimenta el análisis** (Hair et al., 2021).

La discusión sobre tamaño muestral también debe relacionarse con la capacidad predictiva del modelo. Un modelo puede mostrar relaciones significativas dentro de la muestra analizada, pero tener bajo desempeño predictivo fuera de ella. Por ello, criterios como Q^2 y **PLSpredict** requieren suficiente base empírica para ofrecer resultados confiables. Si la muestra es demasiado pequeña, las predicciones pueden ser inestables y poco generalizables. En modelos orientados a explicación-predicción, esta situación es especialmente importante porque la meta no es solo confirmar relaciones teóricas, sino también anticipar comportamientos futuros. **La**

capacidad predictiva depende no solo del modelo conceptual, sino también de la calidad y suficiencia de la muestra utilizada para estimar, validar y evaluar el modelo (Shmueli, 2010).

La viabilidad del modelo incluye también la revisión de la tasa de respuesta y del acceso real a la población. Muchos estudios planean muestras amplias, pero enfrentan dificultades prácticas: baja participación, rechazo de organizaciones, cuestionarios incompletos o acceso limitado a informantes clave. Por ello, el investigador debe estimar desde el inicio cuántas respuestas puede obtener realmente y cuánto tiempo requerirá el trabajo de campo. En administración, los directivos, empresarios y especialistas suelen tener disponibilidad limitada, lo que puede afectar la recolección de datos. Diseñar un modelo extremadamente complejo sin considerar estas limitaciones puede poner en riesgo el estudio completo. **La planeación muestral debe ser realista y compatible con las condiciones prácticas de acceso a la información**. La viabilidad empírica es parte del rigor metodológico (Green, 1991).

La calidad de la muestra también debe evaluarse desde la perspectiva de la representatividad. Aunque PLS-SEM no exige necesariamente muestras probabilísticas estrictas en todos los contextos aplicados, el investigador debe justificar cómo los participantes representan la población objetivo. Por ejemplo, si un estudio analiza innovación en pymes manufactureras, la muestra debe incluir organizaciones que realmente pertenezcan a ese contexto. Si se utilizan muestras de conveniencia, debe reconocerse esta limitación y discutir su impacto sobre la generalización de resultados. **La representatividad fortalece la capacidad del modelo para producir inferencias pertinentes y defendibles**. El número de casos es importante, pero también lo es la correspondencia entre la muestra y el fenómeno estudiado (Hair et al., 2021).

La potencia estadística debe interpretarse junto con el tamaño del efecto. En ocasiones, una relación puede ser estadísticamente significativa porque la muestra es muy grande, aunque el efecto real sea pequeño. Por ejemplo, un coeficiente *path* muy bajo puede resultar significativo con cientos o miles de observaciones. Esto obliga al investigador a no depender únicamente de valores p, sino también de medidas de tamaño del efecto como f^2 . Un efecto pequeño puede ser relevante en ciertos contextos, pero debe interpretarse con prudencia. Del mismo modo, una relación moderada puede no alcanzar significancia si la muestra es insuficiente. **La interpretación metodológica debe equilibrar significancia estadística, tamaño del efecto y potencia analítica**. Ningún criterio por sí solo es suficiente para evaluar la importancia de una relación estructural (Cohen, 1992).

La viabilidad del modelo también exige revisar la proporción entre número de indicadores y número de casos. Un modelo con demasiados indicadores respecto a la muestra disponible puede generar estimaciones inestables. Esto es especialmente importante cuando se utilizan escalas largas o múltiples dimensiones. Por ejemplo, un modelo con diez constructos y ocho indicadores por constructo implica ochenta variables observadas, lo que incrementa la complejidad de la estimación. En estos casos, puede ser conveniente revisar si todos los indicadores son realmente

necesarios o si algunas escalas pueden simplificarse sin perder cobertura conceptual. **La economía de indicadores puede mejorar la viabilidad del modelo sin sacrificar calidad conceptual**, siempre que las decisiones se justifiquen adecuadamente (Hair et al., 2021).

En estudios con muestras relativamente pequeñas, PLS-SEM suele considerarse más flexible que CB-SEM. Sin embargo, esta flexibilidad no significa ausencia de requisitos metodológicos. PLS-SEM puede funcionar adecuadamente con muestras moderadas cuando el modelo está bien especificado y los efectos son suficientemente fuertes, pero sigue requiriendo coherencia conceptual, calidad de indicadores y potencia suficiente. La idea de que "PLS-SEM funciona con cualquier muestra pequeña" es una simplificación incorrecta. **La calidad del modelo no depende solo del método utilizado, sino de la correspondencia entre complejidad estructural, calidad de datos y suficiencia muestral** (Hair et al., 2019).

Desde una perspectiva pedagógica, el tema de tamaño de muestra y potencia estadística ayuda al Investigador a comprender que el análisis estructural no consiste únicamente en correr software. Antes de interpretar coeficientes, AVE, HTMT, R^2 o Q^2 , el investigador debe asegurarse de que el modelo tiene soporte empírico suficiente. Esta revisión obliga a conectar teoría, diseño conceptual, acceso a datos, calidad de medición y capacidad analítica. **La muestra no es un requisito administrativo del estudio; es el fundamento empírico que sostiene la credibilidad de las relaciones estructurales**. Un modelo teóricamente sólido puede fracasar si no cuenta con suficiente soporte estadístico; del mismo modo, una gran muestra no compensa un modelo conceptualmente débil (Hair et al., 2021).

En síntesis, el **tamaño de muestra** y la **potencia estadística** son condiciones esenciales para la viabilidad del modelo PLS-SEM. La muestra debe evaluarse considerando complejidad estructural, número de predictores, tamaño esperado del efecto, mediaciones, moderaciones y calidad de los datos. La potencia estadística permite valorar la capacidad del estudio para detectar relaciones reales, evitando interpretaciones erróneas derivadas de muestras insuficientes. Aunque la **regla de 10 veces** puede utilizarse como referencia preliminar, métodos más robustos como el **inverse square root method** y el **gamma-exponential method** ofrecen justificaciones más sólidas para investigaciones avanzadas. Además, la interpretación de resultados debe integrar significancia, tamaño del efecto y suficiencia muestral. En consecuencia, **la viabilidad del modelo SEM depende del equilibrio entre teoría, complejidad analítica y capacidad real de obtener datos adecuados** (Kock & Hadaya, 2018).

Conclusiones

El Capítulo 5 permitió comprender que la evaluación de un modelo PLS-SEM no inicia con la interpretación de coeficientes estructurales, sino con la correcta **especificación y evaluación del modelo de medición**. Antes de interpretar relaciones entre constructos, el investigador debe justificar si cada constructo será tratado como **reflectivo, formativo, compuesto o jerárquico**, porque cada lógica de

medición exige criterios distintos. Los constructos reflectivos requieren consistencia interna, cargas externas, validez convergente y validez discriminante; los constructos formativos y compuestos requieren revisar pesos, relevancia conceptual, colinealidad y significancia; y los constructos jerárquicos exigen decidir cómo se articularán los constructos de orden inferior y superior dentro de PLS-SEM. Esta distinción evita aplicar una misma regla estadística a estructuras conceptuales diferentes y protege la coherencia entre teoría, medición e interpretación (Jarvis et al., 2003).

El capítulo también mostró que la calidad del modelo de medición no puede reducirse a cumplir umbrales. Indicadores como alfa de Cronbach, rho_A, rho_c, AVE, HTMT, VIF o cargas externas deben interpretarse como **evidencia técnica orientativa**, no como decisiones automáticas. Un valor aceptable puede fortalecer la medición, pero no sustituye la revisión conceptual del constructo, la claridad semántica de los indicadores ni la pertinencia de la escala. Del mismo modo, un valor problemático no siempre exige eliminar indicadores; puede indicar necesidad de revisar redacción, redundancia, solapamiento conceptual, mala asignación de ítems o falta de diferenciación entre constructos. Por ello, la evaluación en PLS-SEM debe integrar criterio estadístico, teoría sustantiva y juicio metodológico (Hair et al., 2021).

Finalmente, el Capítulo 5 establece la base técnica para avanzar hacia el modelo estructural. La confiabilidad y la validez convergente aseguran que los indicadores representan adecuadamente sus constructos; la validez discriminante confirma que los constructos conservan identidad propia; la colinealidad permite detectar redundancias entre indicadores o predictores; el sesgo de método común advierte posibles contaminaciones derivadas del procedimiento de recolección de datos; y el tamaño de muestra y la potencia estadística ayudan a valorar la viabilidad de la estimación. En conjunto, estos criterios permiten defender que el modelo no solo está estimado, sino **correctamente medido, conceptualmente diferenciado y metodológicamente preparado** para la evaluación estructural posterior (Henseler et al., 2015). Véase la **Tabla 5.**

Tabla 5. Del constructo al indicador

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación / criterio orientativo	Referencias
Alfa de Cronbach	Índice clásico de consistencia interna que estima la homogeneidad entre indicadores de un constructo reflectivo.	Ayuda a valorar si los ítems se comportan como manifestaciones coherentes de una misma variable latente.	Valores ≥ 0.70 suelen considerarse aceptables; valores muy altos pueden sugerir redundancia de indicadores.	Churchill (1979)
Análisis de tétradas confirmatorio, CTA	Procedimiento que permite examinar si una especificación reflectiva es empíricamente defendible	Apoya la revisión de la especificación del modelo de medición, especialmente cuando existe	Una tétrada no redundante significativamente distinta de cero puede alertar sobre posible mala especificación.	Gudergan et al. (2008)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación / criterio orientativo	Referencias
	mediante restricciones entre covarianzas.	duda entre lógica reflectiva, formativa o compuesta.		
AVE, varianza media extraída	Índice de validez convergente que expresa la proporción promedio de varianza capturada por el constructo respecto de sus indicadores.	Permite valorar si los indicadores reflectivos comparten suficiente varianza con el constructo.	AVE ≥ 0.50 indica que el constructo explica al menos la mitad de la varianza de sus indicadores.	Fornell y Larcker (1981)
Carga externa	Asociación entre un indicador y el constructo reflectivo al que pertenece.	Evalúa la confiabilidad individual del indicador dentro del modelo de medición reflectivo.	$\lambda \geq 0.708$ es criterio recomendado; cargas entre 0.40 y 0.708 requieren análisis conceptual antes de eliminar.	Hair et al. (2019)
Colinealidad	Situación en la que indicadores o constructos predictores comparten demasiada información entre sí.	Permite detectar redundancia entre indicadores formativos, compuestos o predictores estructurales.	VIF ≤ 3.3 es un criterio conservador; valores elevados exigen revisar redundancia conceptual.	Kock (2015)
Constructo compuesto	Entidad analítica formada por la combinación de indicadores o componentes funcionales del fenómeno.	Representa capacidades, prácticas, recursos o resultados heterogéneos que adquieren sentido al integrarse.	No debe evaluarse como reflectivo puro; requiere justificar la contribución de cada componente.	Guenther et al. (2023)
Constructo formativo	Constructo en el que los indicadores contribuyen a formar el significado total del concepto.	Permite modelar fenómenos integrados por componentes no intercambiables.	Se evalúa mediante pertinencia conceptual, pesos externos, significancia, cargas y VIF; no mediante consistencia interna.	Diamantopoulos y Winklhofer (2001)
Constructo jerárquico, HOC/LOC	Estructura en la que un constructo de orden superior se representa mediante constructos de orden inferior o dimensiones.	Permite modelar fenómenos complejos con mayor nivel de abstracción y parsimonia.	Puede estimarse mediante indicadores repetidos, enfoque integrado de dos etapas o enfoque disociado de dos etapas.	Becker et al. (2012)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación / criterio orientativo	Referencias
Constructo reflectivo	Constructo cuyos indicadores son manifestaciones observables de una variable latente común.	Representa fenómenos donde el constructo causa las respuestas de los indicadores.	Sus indicadores deben mostrar cargas adecuadas, consistencia interna, AVE y validez discriminante.	Jarvis et al. (2003)
Confiabilidad compuesta, rho_c	Índice de consistencia interna que pondera los indicadores según sus cargas reales.	Complementa al alfa de Cronbach en la evaluación de constructos reflectivos.	Valores entre 0.70 y 0.90 suelen ser adecuados; valores > 0.95 pueden sugerir redundancia.	Hair et al. (2021)
Full collinearity assessment	Evaluación de colinealidad completa que revisa los VIF de los constructos como predictores para detectar colinealidad generalizada.	Apoya el diagnóstico de posible sesgo de método común y redundancia conceptual entre constructos.	VIF > 3.3 puede sugerir alerta metodológica, pero no prueba automáticamente sesgo de método común.	Kock y Lynn (2012)
HTMT	Ratio heterotrait-monotrait utilizado para evaluar validez discriminante entre constructos.	Permite verificar si dos constructos son empíricamente distinguibles.	HTMT < 0.85 es criterio conservador; HTMT < 0.90 puede aceptarse cuando los constructos son cercanos.	Henseler et al. (2015)
Indicadores repetidos	Enfoque para estimar constructos jerárquicos asignando al constructo de orden superior los indicadores de los constructos de orden inferior.	Facilita la estimación de HOC/LOC en modelos PLS-SEM.	Es sencillo, pero puede generar problemas en configuraciones formativas o cuando el HOC funciona como variable dependiente.	Ringle et al. (2012)
Modelo de medición	Parte del modelo SEM que especifica la relación entre constructos e indicadores.	Determina cómo se representa empíricamente cada constructo antes de evaluar relaciones estructurales.	Debe especificarse antes de aplicar criterios de confiabilidad, validez, colinealidad o significancia.	Chin (1998)
Pesos externos	Coeficientes que indican la contribución relativa de cada indicador en constructos	Permiten valorar qué componente aporta más al constructo formado.	Deben interpretarse junto con significancia, cargas, VIF y relevancia conceptual.	Diamantopoulos y Winklhofer (2001)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación / criterio orientativo	Referencias
	formativos o compuestos.			
Rho_A	Coeficiente de confiabilidad de Dijkstra-Henseler asociado a modelos reflectivos y PLSc.	Ofrece una estimación de confiabilidad más consistente que alfa y menos liberal que rho_c.	Valores ≥ 0.70 suelen considerarse aceptables; debe distinguirse de la confiabilidad compuesta.	Dijkstra y Henseler (2015)
Sesgo de método común, CMB	Varianza atribuible al procedimiento de medición más que a los constructos sustantivos.	Permite revisar si las relaciones observadas pueden estar infladas o distorsionadas por el diseño de recolección.	Debe prevenirse mediante diseño del instrumento y diagnosticarse con prudencia; no se resuelve solo con una prueba estadística.	Podsakoff et al. (2024)
Tamaño de muestra	Número de observaciones disponibles para estimar el modelo.	Condiciona la estabilidad de las estimaciones, la potencia estadística y la viabilidad del modelo.	Debe ser coherente con la complejidad del modelo, número de relaciones, efectos esperados y propósito del estudio.	Cohen (1992)
Validez convergente	Evidencia de que los indicadores de un constructo comparten suficiente varianza común.	Permite verificar si los indicadores realmente convergen en el constructo que buscan medir.	Se evalúa principalmente mediante AVE ≥ 0.50 en constructos reflectivos.	Fornell y Larcker (1981)
Validez discriminante	Evidencia de que los constructos son empíricamente distintos entre sí.	Protege la interpretación de las relaciones estructurales entre constructos.	Se revisa mediante HTMT, Fornell-Larcker, cargas cruzadas y diferenciación conceptual.	Henseler et al. (2015)
VIF	Factor de inflación de la varianza que mide colinealidad entre indicadores o predictores.	Diagnostica redundancia y estabilidad de indicadores formativos, compuestos o predictores estructurales.	VIF ≤ 3.3 es criterio conservador; valores altos requieren revisar solapamiento conceptual.	Kock (2015)

Fuente: recopilación y elaboración propia

CAPÍTULO 6. Robustez, mediación, moderación, MICOM, MGA y reporte

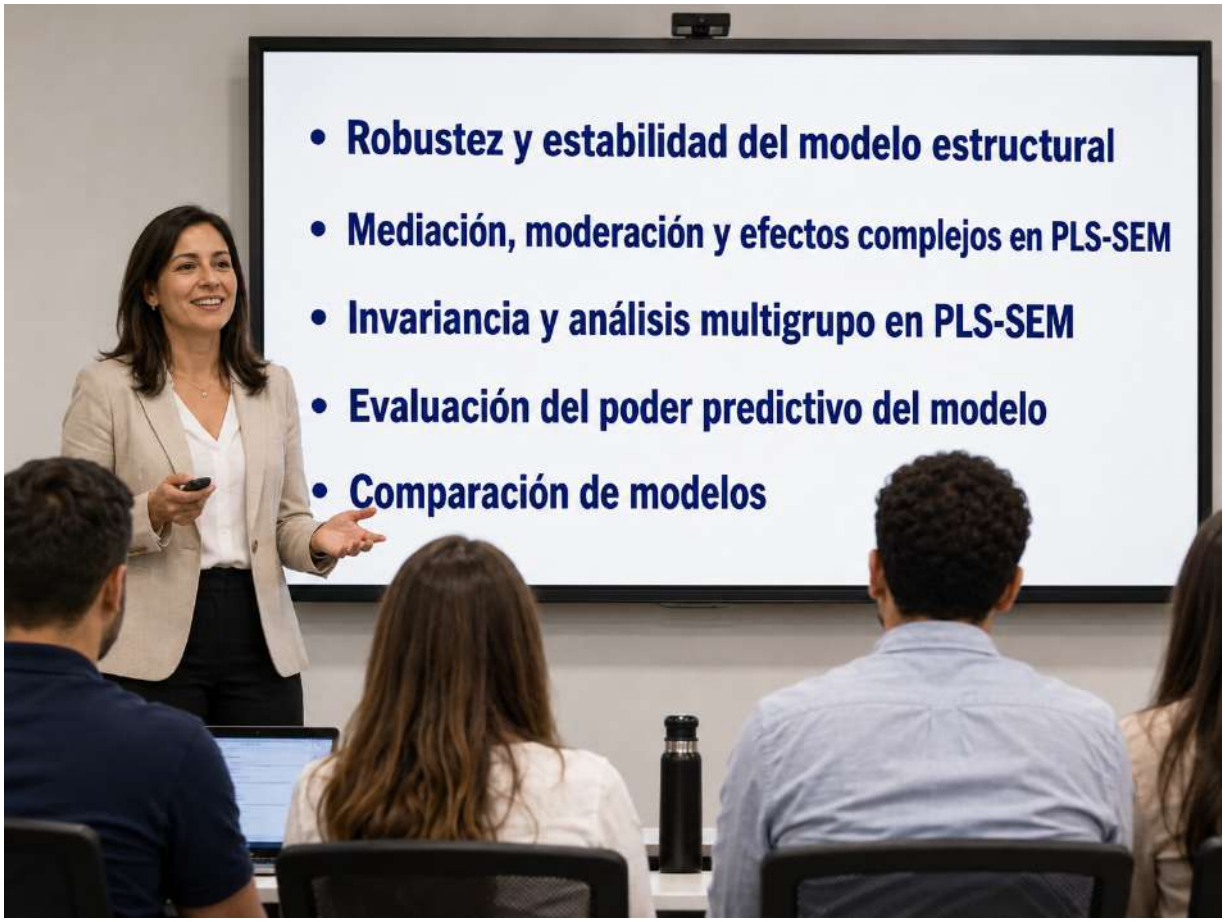

El Capítulo 6 aborda la evaluación avanzada del modelo estructural en PLS-SEM. Una vez que el modelo de medición ha sido especificado y evaluado mediante criterios de confiabilidad, validez convergente, validez discriminante, colinealidad, sesgo de método común y calidad de indicadores, el análisis debe avanzar hacia la interpretación de las relaciones entre constructos. En esta etapa, el investigador ya no se pregunta únicamente si los indicadores representan adecuadamente a sus variables latentes, sino si el sistema de relaciones planteado por la teoría es **estadísticamente estable, conceptualmente coherente, predictivamente útil y metodológicamente defendible**. Por ello, el capítulo examina coeficientes *path*, significancia, intervalos de confianza, R^2, f^2, Q^2, PLSpredict, endogeneidad, relaciones no lineales y criterios de estabilidad estructural. La evaluación del modelo estructural no debe reducirse a aceptar o rechazar hipótesis; debe mostrar si las relaciones propuestas tienen dirección, magnitud, relevancia sustantiva y coherencia con el propósito del estudio (Hair et al., 2021)

El capítulo también incorpora el análisis de **mediación, moderación y efectos complejos**, porque muchos fenómenos administrativos no se explican mediante relaciones directas simples. En áreas como innovación, transformación digital, aprendizaje organizacional, desempeño, adopción tecnológica o sostenibilidad, suele ser necesario analizar **cómo** ocurre una relación, **bajo qué condiciones** se fortalece o debilita, y **qué mecanismos intermedios** conectan los antecedentes y los resultados. **La mediación identifica procesos explicativos; la moderación reconoce condiciones contextuales; y la mediación moderada analiza si un efecto indirecto cambia según una variable moderadora.** Esta parte del capítulo evita que PLS-SEM se use solo como una red de flechas significativas y lo convierte en una herramienta para interpretar mecanismos, contingencias y configuraciones relacionales más complejas (Nitzl et al., 2016).

Asimismo, el capítulo incorpora la invariancia de medición y el análisis multigrupo mediante los procedimientos **MICOM (*measurement invariance of composite models*) y MGA (*multi-group analysis*)**. Esta sección resulta fundamental porque, antes de comparar grupos, el investigador debe demostrar que los constructos se miden de manera equivalente entre ellos. En efecto, comparar diferencias entre hombres y mujeres, regiones, sectores, generaciones o tipos de organización sin verificar previamente la invariancia puede conducir a interpretaciones erróneas, al atribuir las diferencias a relaciones estructurales cuando, en realidad, podrían derivarse de una medición no equivalente. En este sentido, el procedimiento **MICOM** permite evaluar la invariancia configuracional, la invariancia composicional y la igualdad de medias y varianzas de los compuestos, con el fin de establecer si existe invariancia parcial o completa. Una vez cumplidas las condiciones necesarias de invariancia, el **MGA** permite comparar diferencias entre los coeficientes *path* de distintos grupos, fortaleciendo así la validez de las conclusiones en modelos PLS-SEM aplicados a contextos heterogéneos (Henseler et al., 2016).

El capítulo amplía la evaluación estructural mediante criterios de **predicción, utilidad aplicada y comparación de modelos**. En PLS-SEM, un modelo puede explicar varianza dentro de la muestra y, sin embargo, no predecir adecuadamente **casos nuevos o datos fuera de muestra**. Por esta razón, el análisis predictivo mediante Q^2, PLSpredict, Q^2_predict, RMSE y MAE permite valorar si el modelo tiene capacidad para anticipar resultados fuera de la estimación directa. A esta lógica se suman herramientas como l**PMA** (*Importance–Performance Map Analysis),* **NCA** (*Necessary Condition Analysis*) y **clPMA** (*Combined Importance–Performance Map Analysis*), que ayudan a traducir los resultados en prioridades interpretativas: qué constructos son importantes, cuáles tienen bajo rendimiento, cuáles son condiciones necesarias y qué variables deben atenderse para alcanzar niveles altos de la variable objetivo. Así, la evaluación estructural no se limita a confirmar hipótesis, sino que también orienta decisiones, identifica oportunidades de mejora y compara alternativas explicativas o predictivas (Shmueli et al., 2019).

En conjunto, el Capítulo 6 muestra que un modelo PLS-SEM robusto no es aquel que acumula más índices, más flechas o más pruebas, sino aquel que logra articular

teoría, medición, explicación, predicción, comparación y reporte dentro de una lógica metodológica transparente. La robustez exige revisar la colinealidad estructural, la significancia, el tamaño del efecto, la relevancia predictiva, la endogeneidad y la heterogeneidad, los efectos indirectos, las moderaciones, la invariancia y la capacidad de reporte. También exige prudencia: un coeficiente significativo no prueba causalidad absoluta, un R^2 alto no garantiza validez teórica y una predicción aceptable no sustituye la explicación conceptual**. Por ello, este capítulo orienta al investigador para sustentar el modelo estructural como un sistema de relaciones estimadas, evaluadas y contextualizadas, y no como una salida automática del software** (Guenther et al., 2023).

Robustez y estabilidad del modelo estructural

La robustez del modelo estructural en PLS-SEM se refiere a la capacidad del modelo para sostener resultados interpretables, coherentes y defendibles más allá de una lectura básica de significancia estadística. Después de validar el modelo de medición mediante confiabilidad, validez convergente, validez discriminante, colinealidad, sesgo de método común y calidad de indicadores, el análisis PLS-SEM debe avanzar hacia la evaluación del **modelo estructural**. Esta fase tiene como propósito determinar si las relaciones planteadas entre constructos poseen **coherencia estadística, capacidad explicativa y utilidad predictiva**. Mientras el modelo de medición responde si los constructos fueron representados adecuadamente por sus indicadores, el modelo estructural responde si dichos constructos se relacionan entre sí de acuerdo con la lógica teórica del estudio. En esta etapa, el investigador ya no pregunta únicamente si el constructo fue medido con consistencia, sino si el sistema conceptual permite explicar o anticipar el fenómeno central. Por ello, se revisan coeficientes *path*, significancia, R^2, f^2, Q^2, PLSpredict y coherencia de resultados. **La calidad estructural no depende de un solo índice, sino de la convergencia entre teoría, medición y evidencia empírica** (Hair et al., 2021).

El primer paso consiste en confirmar que los constructos predictivos no presenten colinealidad estructural severa. Aunque la colinealidad ya fue revisada en el tema anterior, aquí se examina desde la perspectiva de las relaciones entre constructos que explican una misma variable endógena. Si varios predictores son demasiado similares, los coeficientes *path* pueden volverse inestables, perder significancia o cambiar de signo. Por ejemplo, si **capacidad digital**, **madurez digital** y **transformación digital** se usan simultáneamente para explicar desempeño innovador, el modelo puede tener dificultades para distinguir cuál aporta realmente al resultado. El criterio usual es revisar el **VIF —*Variance Inflation Factor*—**, donde valores menores a **3.3** representan una referencia conservadora y valores menores a **5.0** pueden aceptarse en ciertos contextos aplicados. Sin embargo, el VIF no debe leerse mecánicamente. Un valor elevado puede señalar redundancia conceptual, sobrefragmentación de constructos o problemas de especificación. **Antes de interpretar coeficientes, debe comprobarse que cada predictor aporte información diferenciada** (Hair et al., 2019).

Los **coeficientes *path*** son el núcleo de la evaluación estructural, porque indican la dirección y magnitud de las relaciones entre constructos. Un coeficiente positivo sugiere que al aumentar el predictor también aumenta la variable dependiente; un coeficiente negativo indica una relación inversa. Sin embargo, estos coeficientes no deben interpretarse como causalidad absoluta. En la mayoría de estudios administrativos basados en encuestas transversales, lo más prudente es hablar de **relaciones estructurales estimadas**, **efectos hipotetizados** o **influencias teóricamente esperadas**. Por ejemplo, si la capacidad digital muestra un coeficiente positivo sobre desempeño innovador, puede interpretarse como evidencia de que mayores capacidades digitales se asocian con mayor desempeño innovador dentro del modelo propuesto. No obstante, esa interpretación debe estar respaldada por teoría, diseño y calidad de medición. **Un coeficiente *path* solo tiene sentido si la relación fue conceptualmente justificada antes de estimarse** (Chin, 1998).

La magnitud del coeficiente *path* debe interpretarse con cuidado. Un coeficiente elevado puede parecer atractivo, pero si la relación no tiene fundamento teórico, puede ser difícil de defender. De manera inversa, un coeficiente moderado o pequeño puede ser sustantivamente relevante en fenómenos complejos, especialmente cuando se estudian actitudes, capacidades, innovación, sostenibilidad o desempeño organizacional. En ciencias de la administración, los fenómenos rara vez dependen de una sola variable; por ello, **efectos moderados pueden representar contribuciones importantes**. El investigador debe evitar una lectura simplista basada únicamente en “grande” o “pequeño”. La interpretación debe considerar el contexto, la teoría, el número de predictores y la complejidad del fenómeno. Por ejemplo, un efecto de aprendizaje organizacional sobre innovación puede ser moderado, pero relevante si explica un mecanismo clave del modelo. **La importancia de una relación no se define solo por su tamaño numérico, sino por su papel dentro del sistema conceptual** (Hair et al., 2021).

La significancia de los coeficientes *path* suele evaluarse mediante *bootstrapping*, procedimiento de remuestreo que genera múltiples submuestras a partir de la muestra original. Este método permite estimar errores estándar, valores t, valores p e intervalos de confianza sin exigir supuestos estrictos de normalidad multivariada. En PLS-SEM, el *bootstrapping* es especialmente útil porque el método está orientado a modelos basados en varianza. Sin embargo, el investigador debe evitar reducir la interpretación a si el valor p es menor que 0.05. La significancia indica que el efecto observado tiene baja probabilidad de deberse al azar bajo ciertas condiciones, pero no garantiza relevancia práctica ni fuerza teórica. Por ello, debe interpretarse junto con el coeficiente *path*, el tamaño del efecto, la capacidad explicativa y la coherencia conceptual. **Una relación estadísticamente significativa puede ser metodológicamente débil si su magnitud es mínima o si contradice la lógica teórica sin explicación suficiente** (Hair et al., 2021).

Los intervalos de confianza derivados del *bootstrapping* ofrecen una lectura más rica que el valor p aislado. Si el intervalo de confianza de una relación no incluye el cero, suele interpretarse como evidencia de significancia. Además, el intervalo

permite observar la precisión de la estimación. Un intervalo estrecho sugiere mayor estabilidad; uno muy amplio puede indicar incertidumbre. Esta información es relevante porque dos relaciones pueden tener valores p similares, pero distinta precisión. Por ejemplo, una relación puede ser significativa pero con un intervalo amplio, lo que sugiere cautela. En estudios con muestras pequeñas o efectos débiles, esta revisión es especialmente útil. **El intervalo de confianza ayuda a interpretar no solo si existe una relación, sino qué tan estable parece ser la estimación dentro del procedimiento de remuestreo**. Por ello, reportar intervalos fortalece la transparencia metodológica del análisis estructural (Hair et al., 2021).

La evaluación estructural debe incorporar el coeficiente de determinación R^2, que indica la proporción de varianza explicada en una variable endógena por sus predictores. En términos simples, R^2 responde a la pregunta: **¿cuánto del fenómeno dependiente logra explicar el modelo?**. Por ejemplo, un R^2 de 0.60 en desempeño innovador sugiere que el 60% de su variación es explicada por los constructos antecedentes incluidos. Sin embargo, no existe un umbral universal válido para todos los campos. En fenómenos sociales y administrativos, valores moderados pueden ser relevantes porque el comportamiento organizacional suele depender de múltiples factores contextuales. Un R^2 bajo no necesariamente invalida un modelo si el fenómeno es complejo o si el propósito es explorar relaciones iniciales. A la vez, un R^2 alto tampoco garantiza calidad si se obtiene mediante constructos redundantes o mal diferenciados. **El R^2 debe interpretarse según la naturaleza del fenómeno, el propósito del estudio y la calidad conceptual del modelo** (Hair et al., 2019).

El R^2 puede ser útil para evaluar la **capacidad explicativa global** de cada variable endógena, pero no debe confundirse con prueba causal definitiva. Un modelo puede explicar una proporción importante de varianza sin demostrar causalidad fuerte, especialmente si se basa en datos transversales. Además, el R^2 puede aumentar cuando se agregan más predictores, incluso si algunos aportan poco valor conceptual. Por ello, maximizar R^2 no debe ser el objetivo único. Un modelo parsimonioso con R^2 moderado y relaciones bien justificadas puede ser más valioso que un modelo sobrecargado con R^2 alto pero baja claridad conceptual. En PLS-SEM, la orientación explicativa-predictiva invita a revisar R^2, pero siempre junto con f^2, Q^2 y coherencia teórica. **La explicación estadística debe estar subordinada a una arquitectura conceptual defendible** (Shmueli, 2010).

El tamaño del efecto f^2 complementa al R^2 porque permite evaluar el aporte específico de cada predictor a una variable endógena. Mientras R^2 muestra la varianza explicada total, f^2 indica cuánto se reduce esa explicación cuando un predictor se elimina del modelo. Así, permite conocer si una relación aporta poco, moderadamente o mucho a la explicación del fenómeno. Como orientación, valores alrededor de **0.02** se consideran pequeños, **0.15** medianos y **0.35** grandes. Sin embargo, estos criterios deben contextualizarse. En administración, un efecto pequeño puede ser importante si se trata de una relación novedosa, difícil de intervenir o relevante para la teoría. De igual manera, un efecto grande debe revisarse si existe colinealidad o solapamiento conceptual. **El f^2 ayuda a distinguir entre relaciones**

significativas y relaciones sustantivamente influyentes dentro del modelo (Cohen, 1992).

El análisis del f^2 también ayuda a evitar conclusiones exageradas. Una relación puede ser significativa debido a un tamaño de muestra grande, pero tener un efecto muy pequeño. En ese caso, el investigador debe reconocer que la relación existe estadísticamente, pero su aporte explicativo puede ser limitado. Por ejemplo, una variable de control puede tener significancia, pero aportar poca varianza adicional al desempeño innovador. En cambio, una relación no significativa con f^2 bajo puede sugerir que el predictor tiene escaso valor dentro del modelo actual. Esta lectura permite discutir resultados con mayor madurez. **No basta con aceptar o rechazar hipótesis; es necesario valorar cuánto aporta cada relación al sistema estructural**. De esta manera, el modelo no se interpreta solo desde valores p, sino desde la combinación entre significancia, magnitud y utilidad explicativa (Hair et al., 2021).

La evaluación estructural incorpora también la **relevancia predictiva Q^2** , tradicionalmente asociada al procedimiento de blindfolding. El Q^2 evalúa si el modelo posee capacidad para reconstruir datos observados de los constructos endógenos. Como orientación general, valores de Q^2 mayores que cero indican relevancia predictiva. Este criterio es importante porque un modelo puede tener relaciones significativas y R^2 aceptable, pero limitada capacidad predictiva. En PLS-SEM, donde suele buscarse explicación y predicción, Q^2 permite ampliar la evaluación más allá de la explicación interna de la muestra. **Un modelo estructural no solo debe explicar relaciones teóricas; también puede evaluarse por su capacidad para anticipar valores empíricos relevantes** (Hair et al., 2021).

El Q^2 debe interpretarse como una evidencia de relevancia predictiva, no como prueba absoluta de poder predictivo externo. Su función es indicar si el modelo tiene utilidad para predecir constructos endógenos bajo el procedimiento aplicado. Si Q^2 es mayor que cero, se considera que el modelo tiene capacidad predictiva aceptable para ese constructo. Si Q^2 es igual o menor que cero, el modelo carece de relevancia predictiva suficiente en esa parte del sistema. Esta lectura permite detectar variables endógenas mejor o peor representadas por el modelo. Por ejemplo, un modelo puede tener buena predicción para satisfacción, pero baja para lealtad. **La capacidad predictiva puede variar entre constructos endógenos, por lo que debe revisarse de manera específica y no solo global** (Hair et al., 2021).

La evaluación predictiva puede complementarse mediante PLSpredict, procedimiento diseñado para valorar el desempeño predictivo del modelo PLS frente a modelos de referencia. PLSpredict utiliza particiones de datos para analizar qué tan bien el modelo predice casos no usados directamente en la estimación. Sus métricas principales incluyen **RMSE —*Root Mean Squared Error*—** y **MAE —*Mean Absolute Error*—**. Valores menores de error indican mejor desempeño predictivo. Si el modelo PLS genera menores errores que un modelo lineal de referencia, puede considerarse que posee capacidad predictiva favorable. Esta evaluación es especialmente relevante cuando el propósito investigativo incluye predicción.

PLSpredict permite distinguir entre un modelo que ajusta bien dentro de la muestra y un modelo que puede anticipar adecuadamente observaciones nuevas (Hair et al., 2021).

La incorporación de PLSpredict fortalece la lógica contemporánea de PLS-SEM porque responde a la distinción entre explicar y predecir. Un modelo puede explicar relaciones teóricas dentro de la muestra, pero no necesariamente predecir bien fuera de ella. De igual forma, un modelo puede predecir adecuadamente sin ofrecer una explicación teórica profunda. Por ello, el investigador debe tener claro desde el diseño si su propósito principal es explicativo, predictivo o mixto. Si el estudio busca contribuir a teoría, los coeficientes *path*, R^2 y f^2 serán centrales. Si busca anticipar resultados, Q^2 y PLSpredict deben adquirir mayor peso. **La evaluación estructural debe alinearse con el propósito investigativo declarado; de lo contrario, los índices se reportan sin una lógica metodológica clara** (Shmueli, 2010).

La evaluación global del modelo estructural debe considerar la coherencia entre dirección teórica y resultado empírico. Un coeficiente *path* puede ser significativo, pero si aparece en dirección contraria a la hipótesis, el investigador debe revisar cuidadosamente su interpretación. Por ejemplo, si se esperaba que la **capacidad digital** influyera positivamente en el **desempeño innovador**, pero el coeficiente resulta negativo, no basta con reportar que la hipótesis no se apoyó. Debe analizarse si existe un problema de medición, colinealidad, contexto empírico, mala especificación del modelo o una relación más compleja de lo previsto. En ciencias de la administración, algunos efectos pueden cambiar por condiciones sectoriales, madurez organizacional, restricciones de recursos o resistencia al cambio. Por ello, **un resultado inesperado no debe descartarse automáticamente; debe interpretarse con prudencia teórica y metodológica**. La función del modelo estructural no es confirmar mecánicamente todas las hipótesis, sino ofrecer evidencia para comprender si las relaciones propuestas se sostienen, se matizan o requieren replanteamiento (Gefen et al., 2000).

La evaluación estructural también debe revisar si los resultados son consistentes con el propósito investigativo. Si el estudio fue diseñado para explicar relaciones, la atención debe concentrarse en la dirección, magnitud, significancia y tamaño del efecto de los coeficientes *path*. Si el propósito fue predictivo, deben adquirir mayor relevancia *c,* PLSpredict, RMSE y MAE. Si el modelo declara una orientación explicativa-predictiva, ambos tipos de criterios deben integrarse. Esta distinción es importante porque no todos los índices responden la misma pregunta. R^2 indica capacidad explicativa dentro de la muestra; f^2 muestra el aporte específico de un predictor; Q^2 indica relevancia predictiva; PLSpredict evalúa desempeño predictivo frente a casos no usados directamente en la estimación. **El error metodológico aparece cuando se reportan índices sin vincularlos con el propósito del estudio**. Por ello, la evaluación global debe responder: qué se quería lograr, qué evidencia se obtuvo y qué tan coherente es esa evidencia con el objetivo declarado (Shmueli, 2010).

Un aspecto central es distinguir entre significancia estadística y relevancia sustantiva. Una relación puede ser significativa porque la muestra es grande, pero su contribución al fenómeno puede ser muy pequeña. Del mismo modo, una relación puede no ser significativa, pero resultar teóricamente sugerente si el tamaño de muestra es limitado o si el efecto esperado era pequeño. Por eso, la evaluación estructural no debe reducirse a aceptar o rechazar hipótesis. Debe considerar el coeficiente *path*, los intervalos de confianza, el f^2 , el R^2 y el sentido conceptual de la relación. Por ejemplo, un coeficiente de 0.08 puede alcanzar significancia estadística en una muestra muy amplia, pero su impacto práctico puede ser limitado. En cambio, un coeficiente de 0.20 puede ser relevante en un fenómeno complejo aunque no explique por sí solo toda la varianza. **La interpretación madura de un modelo SEM exige integrar magnitud, significancia, teoría y utilidad práctica** (Cohen, 1992).

Un modelo no es robusto solo porque sus coeficientes *path* sean significativos, porque el R^2 sea aceptable o porque las hipótesis reciban apoyo empírico. Es robusto cuando sus relaciones permanecen razonables frente a revisiones adicionales sobre medición, colinealidad, endogeneidad, predicción, tamaño de muestra, estabilidad de efectos e interpretación teórica. Por ello, la robustez debe entenderse como una **segunda capa de evaluación**: primero se verifica que los constructos estén correctamente especificados y medidos; después, que las rutas estructurales correspondan a hipótesis conceptualmente justificadas; finalmente, que los resultados no dependan de decisiones frágiles, como indicadores débiles, constructos solapados, efectos indirectos omitidos o supuestos no examinados. En ciencias de la administración, esta exigencia es crucial porque muchos modelos trabajan con encuestas transversales, percepciones individuales y variables latentes complejas, lo que puede producir relaciones aparentemente sólidas pero metodológicamente vulnerables. Así, la robustez no debe presentarse como un apartado opcional, sino como una condición para que el modelo pueda generar inferencias académicas prudentes, útiles y trazables. **Un modelo estructural estable es aquel que puede explicar sus resultados, justificar sus decisiones y resistir evaluaciones complementarias sin perder coherencia metodológica** (Hair et al., 2019).

La revisión de robustez también puede incorporar la posibilidad de relaciones no lineales entre constructos. Aunque muchos modelos PLS-SEM se formulan bajo una lógica lineal, algunos fenómenos administrativos pueden presentar efectos curvos, crecientes, decrecientes, acelerados o con rendimientos marginales. Por ejemplo, una mayor inversión tecnológica puede mejorar el desempeño innovador en niveles iniciales, pero después producir saturación, costos de coordinación o complejidad operativa si la organización no cuenta con capacidades suficientes para absorberla. De forma similar, la presión competitiva puede estimular la innovación hasta cierto punto, pero niveles extremos pueden generar decisiones reactivas o reducir la capacidad de aprendizaje. En estos casos, una relación lineal puede ofrecer una lectura incompleta del fenómeno. **Por ello, cuando la teoría, la lógica del caso o los gráficos preliminares lo sugieran, el investigador puede revisar términos cuadráticos o efectos no lineales para comprobar si la relación estructural**

mantiene estabilidad en todo el rango de valores. Esta revisión fortalece la robustez porque evita asumir que una única pendiente representa adecuadamente una relación que podría cambiar según el nivel del predictor (Hair et al., 2021).

La endogeneidad debe tratarse como una amenaza central para la interpretación del modelo estructural, especialmente cuando el estudio pretende sostener explicaciones causales o contrastar hipótesis teóricas. En PLS-SEM, un coeficiente *path* puede ser estadísticamente significativo y, aun así, estar sesgado si alguna variable antecedente se encuentra correlacionada con el término de error de la variable endógena. Esta situación puede aparecer por omisión de variables relevantes, causalidad inversa, simultaneidad entre constructos o especificación incompleta del modelo. **Por ello, la robustez no debe limitarse a revisar colinealidad, R^2 , f^2 o significancia de rutas; también debe valorar si existen razones teóricas para sospechar que una relación estructural está afectada por endogeneidad**. En investigaciones de administración, marketing, innovación o comportamiento organizacional, este control es especialmente importante porque los datos suelen provenir de encuestas transversales y percepciones individuales, lo que exige prudencia al interpretar relaciones como si fueran causales fuertes (Hult et al., 2018; Hair et al., 2021; Guenther et al., 2023).

La endogeneidad ocurre cuando una variable explicativa del modelo está relacionada con el error de la variable que se quiere explicar. Dicho más simple: hay endogeneidad cuando el modelo cree que **X explica Y**, pero en realidad esa relación puede estar contaminada porque falta algo importante, porque la causalidad va al revés, o porque ambas variables se influyen al mismo tiempo. Un ejemplo sencillo: Se quiere probar que **capacidades digitales → desempeño innovador**. Puede haber endogeneidad si:

1. **Falta una variable importante:**
   Por ejemplo, la **cultura organizacional** influye tanto en las capacidades digitales como en el desempeño innovador. Si no se incluye, el efecto de capacidades digitales puede salir inflado o sesgado.
2. **Hay causalidad inversa:**
   Tal vez no solo las capacidades digitales mejoran el desempeño innovador, sino que las empresas más innovadoras también invierten más en capacidades digitales.
3. **Hay simultaneidad:**
   Capacidades digitales y desempeño innovador se alimentan mutuamente al mismo tiempo.

En PLS-SEM, la endogeneidad es importante porque puede hacer que un coeficiente path parezca significativo cuando en realidad está sesgado. Por eso, en el ebook debe explicarse dentro de **robustez del modelo estructural**: antes de interpretar una relación como fuerte, significativa o causal, el investigador debe revisar si pudo existir una variable omitida, una relación inversa o una especificación incompleta. **La endogeneidad representa una amenaza para la interpretación del**

modelo estructural porque aparece cuando una variable explicativa está correlacionada con el error de la variable endógena. En ese caso, el coeficiente estimado puede estar sesgado, aun cuando resulte estadísticamente significativo. Por ello, en PLS-SEM la evaluación de robustez debe considerar posibles variables omitidas, causalidad inversa, simultaneidad o especificaciones incompletas antes de interpretar los resultados como evidencia causal o teóricamente concluyente.

Cuando exista riesgo de endogeneidad, el investigador debe explicitar cómo lo revisó y qué implicaciones tiene para la interpretación de los resultados. Una primera estrategia consiste en justificar teóricamente la inclusión de variables de control o variables instrumentales disponibles, siempre que su incorporación tenga sentido conceptual y no responda solo a una decisión estadística. Otra estrategia consiste en evaluar procedimientos específicos para detectar posibles regresores endógenos en aplicaciones PLS-SEM, especialmente cuando la amenaza proviene de variables omitidas. En cualquier caso, **el objetivo no es eliminar mecánicamente toda incertidumbre, sino demostrar que el modelo fue sometido a una revisión crítica antes de derivar conclusiones**. Si los análisis sugieren ausencia de endogeneidad relevante, el investigador puede interpretar los coeficientes con mayor confianza; si aparece evidencia de endogeneidad, las conclusiones deben reformularse con cautela, reconociendo que la magnitud o significancia de algunas relaciones puede estar sesgada. Así, la evaluación de endogeneidad forma parte de la madurez metodológica del modelo y fortalece la trazabilidad entre teoría, estimación e interpretación (Hult et al., 2018; Hair et al., 2021; Guenther et al., 2023). Con lo anterior, la robustez y estabilidad del modelo estructural, la tenemos definida por:

Justificación adecuada del uso de PLS-SEM. Muchos trabajos aplican PLS-SEM por razones superficiales, como la facilidad del software, la presencia de datos no normales, el tamaño reducido de muestra o la complejidad aparente del modelo. Sin embargo, estas razones solo son aceptables si se integran en una lógica metodológica más amplia. PLS-SEM debe seleccionarse cuando el estudio se orienta a la explicación-predicción, cuando trabaja con modelos relativamente complejos, cuando la teoría está en desarrollo, cuando se requiere estimar modelos con constructos compuestos o cuando la predicción tiene relevancia académica o práctica. La robustez comienza, por tanto, antes de correr el algoritmo: inicia con la coherencia entre problema, pregunta, constructos, medición, datos y técnica. Si el investigador no justifica por qué PLS-SEM es pertinente, el modelo puede ser técnicamente estimable, pero conceptualmente débil. Además, debe reconocerse que los constructos no se observan de forma directa; el modelo genera aproximaciones estadísticas mediante indicadores, lo cual introduce una distancia entre el concepto teórico y su representación empírica. **Cuanto más clara sea la correspondencia entre el propósito del estudio y la técnica empleada, mayor será la estabilidad metodológica del modelo estructural** (Guenther et al., 2023).

La estabilidad de los efectos indirectos, especialmente cuando el modelo incorpora mediadores. En modelos estructurales complejos, un predictor puede no mostrar un efecto directo significativo sobre la variable dependiente, pero sí influir

mediante una variable intermedia. Si el investigador solo revisa las relaciones directas, puede concluir erróneamente que una variable no tiene importancia, cuando en realidad su contribución opera mediante un mecanismo explicativo. La mediación permite responder **cómo o por qué ocurre una relación**, por lo que fortalece la interpretación del modelo. En PLS-SEM, la evaluación moderna de mediación debe centrarse en el efecto indirecto, estimado como producto de rutas, y en su significancia mediante *bootstrapping*. Esta lógica evita depender de enfoques clásicos de pasos causales, que pueden ser insuficientes o engañosos. La robustez aumenta cuando el investigador distingue entre efecto directo, efecto indirecto y efecto total, y cuando clasifica adecuadamente la mediación como complementaria, competitiva, solo indirecta o inexistente. De este modo, el modelo no se interpreta como una red simple de flechas, sino como un sistema de mecanismos. **Una mediación significativa no solo agrega complejidad estadística; aporta profundidad teórica al explicar el proceso mediante el cual una variable influye en otra** (Nitzl et al., 2016).

La invariancia de medición, especialmente cuando se comparan grupos. Si un modelo se analiza en hombres y mujeres, empresas pequeñas y grandes, países distintos, sectores diferentes o grupos con niveles diversos de experiencia, no basta con comparar coeficientes *path*. Antes debe demostrarse que los constructos tienen significado equivalente entre los grupos. De lo contrario, una diferencia estructural podría deberse a que los participantes interpretaron los indicadores de manera distinta, y no necesariamente a que la relación entre variables sea diferente. En modelos basados en composites, el procedimiento MICOM permite evaluar esta comparabilidad mediante tres pasos: invariancia configural, invariancia composicional e igualdad de medias y varianzas. La **invariancia configural** exige que la estructura básica del modelo sea equivalente; la **invariancia composicional** revisa si los composites se forman de manera similar; y la igualdad de medias y varianzas permite establecer una comparabilidad más estricta. Esta revisión es esencial para análisis multigrupo, porque sin invariancia las comparaciones pueden ser metodológicamente inválidas. **La estabilidad del modelo estructural no depende solo de que las rutas sean significativas, sino de que los constructos conserven el mismo significado empírico en los grupos comparados** (Henseler et al., 2016).

La capacidad predictiva fuera de muestra. En muchos estudios PLS-SEM se reporta R^2 como evidencia de capacidad explicativa y Q^2 como indicio de relevancia predictiva. Sin embargo, estos criterios no son suficientes para demostrar que el modelo puede anticipar nuevos casos. Un R^2 elevado indica que el modelo explica varianza dentro de la muestra utilizada, pero no garantiza buen desempeño frente a observaciones no incluidas en la estimación. Por ello, PLSpredict permite evaluar predicción fuera de muestra mediante lógica de entrenamiento y validación. Este procedimiento genera predicciones a nivel de indicador o constructo y compara los errores del modelo PLS-SEM con modelos de referencia, como el modelo lineal. Para interpretar la predicción, deben revisarse Q^2 _predict, RMSE y MAE, así como la distribución de errores. Si el modelo presenta errores menores que el modelo de referencia en la mayoría de los indicadores, puede sostenerse una capacidad predictiva media o alta. **Un modelo estructural robusto no solo debe explicar lo**

observado; también debe mostrar capacidad razonable para anticipar casos nuevos, especialmente cuando promete implicaciones gerenciales o decisiones prácticas (Shmueli et al., 2019).

La evaluación de endogeneidad, especialmente cuando el estudio interpreta sus relaciones como explicativas o causalmente orientadas. La endogeneidad aparece cuando una variable explicativa se encuentra correlacionada con el término de error del modelo, lo que puede ocurrir por variables omitidas, causalidad simultánea, errores de medición o heterogeneidad no observada. En términos prácticos, esto significa que un coeficiente *path* puede estar sesgado y conducir a inferencias incorrectas. En estudios de administración, este riesgo es frecuente porque las investigaciones suelen utilizar encuestas transversales y datos observacionales, donde el investigador no controla experimentalmente las variables. La robustez exige preguntarse si existen variables omitidas relevantes, si las relaciones podrían operar en sentido inverso o si hay factores externos que influyen simultáneamente en antecedente y resultado. En PLS-SEM, la endogeneidad puede abordarse mediante variables de control, variables instrumentales o cópulas gaussianas, dependiendo del diseño y los datos disponibles. No todos los modelos requieren el mismo nivel de tratamiento, pero sí una reflexión explícita. **Si el estudio tiene propósito explicativo, ignorar la endogeneidad puede convertir una relación estadísticamente significativa en una inferencia metodológicamente vulnerable** (Hult et al., 2018). **Cuando exista sospecha de endogeneidad, el investigador debe cerrar la evaluación con un procedimiento explícito.** Una opción es revisar si existen variables de control o variables instrumentales teóricamente defendibles; otra es aplicar cópulas gaussianas cuando el riesgo principal proviene de variables omitidas. Para ello, primero se identifica qué variables independientes podrían ser endógenas; después se comprueba si sus puntuaciones no siguen una distribución normal; posteriormente se incorpora una cópula por cada variable potencialmente endógena asociada con la variable dependiente; y finalmente se evalúa su significancia mediante *bootstrapping*. Si las cópulas gaussianas no resultan significativas, puede sostenerse que la endogeneidad no representa un problema sustantivo para el modelo. Si resultan significativas, los coeficientes estructurales deben interpretarse con cautela, porque alguna relación podría estar sesgada por variables omitidas o por una especificación incompleta del modelo (Hult et al., 2018).

La calidad del reporte académico. Un modelo no es estable para la comunidad científica si sus resultados se presentan de manera incompleta, dispersa o sin trazabilidad. El reporte debe permitir reconstruir el proceso metodológico: por qué se eligió PLS-SEM, cómo se especificaron los constructos, cómo se evaluó el modelo de medición, qué criterios se aplicaron al modelo estructural, qué pruebas complementarias se realizaron y cómo se interpretaron los hallazgos. Esto implica reportar cargas externas, confiabilidad, AVE, HTMT, VIF, coeficientes *path*, valores t, valores p, intervalos de confianza, R^2 , f^2 , Q^2 y, cuando corresponda, PLSpredict, mediación, moderación, MICOM, MGA o endogeneidad. La robustez no consiste en saturar el texto con tablas, sino en mostrar que cada resultado cumple una función dentro de la defensa metodológica. **La transparencia del reporte es una forma de**

estabilidad científica, porque permite que otros investigadores evalúen la coherencia de las decisiones y la solidez de las inferencias. Un criterio omitido, una prueba no reportada o una interpretación sin conexión teórica debilitan el valor del modelo, aunque los resultados parezcan estadísticamente favorables (Hair et al., 2019).

La prevención de malas prácticas en PLS-SEM. Una de las debilidades más comunes en estudios aplicados consiste en usar el método de forma mecánica: seleccionar PLS-SEM sin justificación suficiente, aplicar umbrales de manera rígida, eliminar indicadores solo por criterios estadísticos, interpretar R^2 como prueba de causalidad o asumir que un modelo complejo es automáticamente mejor. La robustez exige evitar estas prácticas mediante decisiones conceptualmente fundamentadas. Por ejemplo, un indicador con carga menor no debe eliminarse automáticamente si su contenido es necesario para la validez conceptual del constructo; de igual forma, un VIF elevado no debe verse solo como problema numérico, sino como posible señal de redundancia conceptual. También debe evitarse presentar PLS-SEM como técnica superior en todos los casos. Su pertinencia depende del propósito, de la naturaleza del modelo y de los datos. **La estabilidad del modelo estructural se debilita cuando el investigador convierte los criterios en recetas y olvida que cada decisión estadística debe responder a una lógica teórica**. Por ello, la robustez debe comprenderse como una práctica reflexiva: revisar resultados, cuestionar supuestos, documentar decisiones y reconocer límites. Esta actitud reduce el riesgo de sobreinterpretar hallazgos y mejora la contribución científica del estudio (Guenther et al., 2023).

La estabilidad del tamaño de muestra y la potencia estadística. Un modelo puede ser conceptualmente atractivo, pero vulnerable si la muestra no permite estimar con precisión sus relaciones. En PLS-SEM, la muestra no debe justificarse solo con reglas simples, sino con una valoración del número de constructos, indicadores, rutas estructurales, tamaño esperado de los efectos y nivel de poder requerido. La estabilidad del modelo depende de que exista suficiente información empírica para detectar efectos reales y evitar conclusiones falsas por falta de potencia. Esto es especialmente importante cuando el modelo incluye mediaciones, moderaciones, comparaciones de grupos o predicción fuera de muestra, porque cada procedimiento aumenta la exigencia analítica. **Una muestra insuficiente puede hacer que efectos relevantes aparezcan como no significativos o que resultados inestables sean interpretados como evidencia sólida**. Por ello, antes de defender un modelo robusto, el investigador debe explicar por qué el tamaño muestral es proporcional a la complejidad del modelo y al propósito del estudio. La estabilidad no se logra aumentando indiscriminadamente variables, sino ajustando la arquitectura del modelo a la evidencia disponible (Kock & Hadaya, 2018).

La calidad previa del modelo de medición. Ninguna prueba estructural puede compensar constructos mal especificados, indicadores ambiguos o escalas débiles. Antes de interpretar rutas, debe verificarse que los constructos reflectivos presenten confiabilidad, validez convergente y validez discriminante; y que los formativos o compuestos tengan indicadores conceptualmente necesarios, pesos interpretables y

colinealidad controlada. **La robustez estructural depende de la robustez de medición**, porque los coeficientes *path* relacionan constructos estimados, no conceptos puros. Si los indicadores no representan adecuadamente el constructo, la relación estructural se vuelve conceptualmente dudosa aunque sea significativa. Por eso, el investigador debe evitar tratar el modelo de medición como trámite técnico. Cada carga externa, AVE, rho_A, rho_c, HTMT o VIF expresa una condición de calidad que sostiene o limita la interpretación posterior. El modelo estructural solo debe evaluarse después de demostrar que la medición es defendible. En este punto, la estabilidad significa que las relaciones analizadas descansan sobre constructos empíricamente distinguibles, conceptualmente coherentes y estadísticamente aceptables (Hair et al., 2021).

La coherencia entre explicación y predicción. PLS-SEM suele presentarse como un enfoque causal-predictivo, pero esto no autoriza mezclar sin control ambos propósitos. Explicar significa comprender por qué ocurre una relación, mientras que predecir significa anticipar resultados con precisión. Un modelo puede explicar bien dentro de la muestra y predecir mal fuera de ella; también puede predecir de forma aceptable sin ofrecer una explicación teórica profunda. Por ello, la robustez exige que el investigador declare si su prioridad es explicar, predecir o combinar ambas finalidades. **La estabilidad del modelo aumenta cuando los criterios usados corresponden al propósito declarado**: para explicación, se revisan hipótesis, coeficientes *path*, significancia, R^2 y f^2; para predicción, se incorporan Q^2, Q^2_predict, RMSE, MAE y comparación con modelos de referencia. La confusión entre explicación y predicción genera interpretaciones exageradas. Un R^2 alto no prueba causalidad, y un *path* significativo no garantiza utilidad predictiva. La robustez consiste en mantener alineados propósito, análisis e interpretación (Shmueli, 2010).

La interpretación conjunta de significancia, tamaño del efecto y relevancia sustantiva. En investigación aplicada, es frecuente que los resultados se reduzcan al valor p. Sin embargo, un efecto estadísticamente significativo puede ser pequeño y poco útil; de igual forma, un efecto no significativo puede requerir revisión de potencia, muestra o especificación. La robustez exige interpretar el coeficiente *path* junto con su intervalo de confianza, valor t, valor p, f^2, R^2 y coherencia teórica. **La significancia estadística responde si existe evidencia contra la hipótesis nula; la relevancia práctica responde si el efecto importa para el fenómeno estudiado**. Esta distinción es clave para evitar modelos "exitosos" solo por acumulación de hipótesis significativas. El investigador debe preguntar: ¿el efecto es suficientemente grande?, ¿aporta explicación incremental?, ¿tiene sentido para la administración?, ¿modifica una decisión teórica o práctica? La estabilidad no depende únicamente de que el resultado sea positivo o significativo, sino de que sea interpretable, proporcional y útil dentro del sistema conceptual del estudio (Cohen, 1992).

La **evaluación de heterogeneidad observada y no observada**. Un modelo estimado en la muestra total puede ocultar patrones diferentes entre subgrupos. Por ejemplo, una relación puede ser fuerte en empresas grandes y débil en pymes; positiva en usuarios expertos y nula en principiantes; o distinta entre sectores industriales. Si

esas diferencias no se examinan, el modelo puede ofrecer una conclusión promedio que no representa adecuadamente a ningún grupo. La estabilidad exige valorar si existen razones teóricas para comparar submuestras y si las mediciones son invariantes antes de realizar análisis multigrupo. Además, puede existir heterogeneidad no observada, es decir, segmentos latentes no identificados por variables visibles. **La robustez estructural implica reconocer que una relación promedio puede esconder configuraciones distintas del fenómeno**. Por ello, cuando el problema de investigación lo justifique, el modelo debe revisarse mediante análisis de grupos, invariancia y procedimientos complementarios de segmentación. Esta revisión no debe hacerse para multiplicar resultados, sino para evitar inferencias generales cuando el fenómeno opera de manera diferenciada (Henseler et al., 2016).

El control del sesgo de método común. Este sesgo aparece cuando las relaciones entre constructos se inflan por utilizar la misma fuente, el mismo instrumento, el mismo momento de medición o formatos de respuesta muy similares. En estudios de administración basados en encuestas, este riesgo es frecuente porque un solo informante puede responder todas las variables del modelo. **Un modelo estructural aparentemente sólido puede reflejar, en parte, artefactos del método y no relaciones sustantivas entre constructos**. La robustez requiere prevenir el problema desde el diseño: anonimato, separación psicológica de variables, redacción clara, reducción de deseabilidad social, escalas equilibradas y, cuando sea posible, fuentes distintas. También puede revisarse estadísticamente mediante aproximaciones como la evaluación de colinealidad completa. Sin embargo, ningún diagnóstico estadístico sustituye un buen diseño. La estabilidad del modelo se fortalece cuando el investigador demuestra que sus relaciones no dependen exclusivamente de un patrón común de respuesta. Por ello, el sesgo de método común debe reconocerse como amenaza metodológica y no como detalle secundario (Podsakoff et al., 2024).

La prudencia en la interpretación causal. PLS-SEM permite estimar relaciones direccionales sustentadas en teoría, pero no convierte automáticamente un estudio transversal en prueba causal fuerte. Para defender causalidad se requieren condiciones adicionales: temporalidad, control de explicaciones alternativas, medición adecuada, diseño apropiado y justificación conceptual sólida. Muchos estudios administrativos utilizan lenguaje de “impacto” o “causa” cuando en realidad han estimado relaciones estructurales con datos observacionales. **La estabilidad científica del modelo aumenta cuando el investigador afirma solo aquello que su diseño puede sostener**. En lugar de declarar causalidad definitiva, puede hablarse de influencia teóricamente esperada, relación estructural estimada o efecto compatible con la hipótesis. Esta prudencia no debilita el estudio; al contrario, lo vuelve metodológicamente más confiable. Un modelo robusto no es el que exagera sus hallazgos, sino el que delimita correctamente su alcance. La interpretación causal debe ser proporcional a la evidencia disponible y a los controles aplicados (Hult et al., 2018).

La replicabilidad lógica del análisis. Un lector debe poder comprender cómo se pasó del problema de investigación al modelo, del modelo a los indicadores, de los indicadores a los índices y de los índices a la interpretación. Si el estudio no permite

reconstruir esa ruta, pierde trazabilidad. **La robustez exige que cada decisión esté documentada y conectada con una razón conceptual o metodológica**. Esto incluye justificar la eliminación de indicadores, el tratamiento de datos faltantes, la selección del número de remuestras bootstrap, la elección de criterios predictivos, la inclusión de mediadores o moderadores y la decisión de comparar grupos. La replicabilidad no significa que otro investigador obtendrá exactamente los mismos resultados en otro contexto, sino que podrá seguir la lógica del análisis y evaluar si fue razonable. En PLS-SEM, donde existen múltiples decisiones posibles, la transparencia es indispensable. La estabilidad no reside solo en los números, sino en la claridad de la cadena de decisiones que los produjo (Hair et al., 2019).

Finalmente, la robustez y estabilidad del modelo estructural deben entenderse como una síntesis entre teoría, medición, estimación, predicción y reporte. Un modelo robusto no es el que acumula más pruebas, sino el que usa las pruebas pertinentes para sostener su propósito investigativo. Si el objetivo es explicar, debe cuidar teoría, hipótesis, endogeneidad, efectos y relevancia sustantiva. Si el objetivo es predecir, debe demostrar desempeño fuera de muestra y errores aceptables. Si compara grupos, debe verificar invariancia. Si incorpora mecanismos, debe analizar efectos indirectos. Si pretende publicación científica, debe reportar con transparencia. **La estabilidad del modelo estructural es, por tanto, una propiedad integral del diseño de investigación**, no un resultado aislado del software. En este sentido, el investigador debe presentar la robustez como evidencia de madurez metodológica: el modelo no solo fue estimado, sino examinado, justificado, interpretado y delimitado. Así, PLS-SEM deja de ser una técnica instrumental y se convierte en una estrategia rigurosa para construir conocimiento administrativo defendible (Guenther et al., 2023).

Mediación, moderación y efectos complejos en PLS-SEM

La mediación, la moderación y los efectos complejos representan una etapa avanzada del análisis estructural porque permiten pasar de modelos lineales simples a modelos capaces de explicar mecanismos, condiciones y patrones relacionales más sofisticados. En PLS-SEM, no basta con afirmar que una variable independiente influye sobre una variable dependiente; en muchos fenómenos administrativos interesa comprender **cómo ocurre esa influencia**, **bajo qué condiciones se fortalece o debilita**, y **qué efecto total produce una combinación de rutas directas e indirectas**. Esta lógica resulta especialmente útil en ciencias de la administración, donde los fenómenos rara vez se explican por relaciones aisladas. La innovación, el desempeño, la adopción tecnológica, la satisfacción, la resiliencia organizacional o la competitividad suelen depender de cadenas de variables, mecanismos internos y condiciones contextuales. Por ello, los efectos complejos no deben añadirse al modelo solo para hacerlo más sofisticado, sino porque responden a una necesidad conceptual derivada del problema de investigación. **Un modelo avanzado no es el que tiene más flechas, sino el que justifica mejor cada ruta**. En este sentido, la mediación y la moderación deben entenderse como extensiones

estructurales que aumentan la capacidad explicativa del modelo cuando se fundamentan teóricamente y se reportan con rigor metodológico (Hair et al., 2019).

La mediación permite analizar si la relación entre una variable antecedente y una variable resultado ocurre a través de una tercera variable intermedia. En términos conceptuales, la mediación responde a la pregunta: **¿por qué o cómo X influye en Y?**. Por ejemplo, las capacidades digitales pueden influir en el desempeño innovador porque fortalecen primero el aprendizaje organizacional; la confianza puede aumentar la intención de adopción tecnológica porque reduce la percepción de riesgo; o el liderazgo transformacional puede mejorar el desempeño porque incrementa el compromiso del equipo. En todos estos casos, el mediador funciona como un mecanismo de transmisión. En PLS-SEM, esta lógica es especialmente importante porque muchos modelos aplicados incluyen cadenas causales esperadas, pero los investigadores a veces se limitan a interpretar efectos directos. Ese error puede producir conclusiones incompletas: una variable puede no tener efecto directo significativo y, aun así, ser relevante por medio de un efecto indirecto. Por ello, la mediación permite enriquecer el análisis estructural al revelar procesos que no son visibles en rutas simples. **Cuando el mediador está bien fundamentado, el modelo gana profundidad teórica**, ya que no solo identifica relaciones, sino que explica el proceso mediante el cual se produce el resultado (Nitzl et al., 2016).

La evaluación de la mediación en PLS-SEM debe centrarse en el efecto indirecto, calculado como el producto de las rutas que conectan el antecedente con el mediador y el mediador con el resultado. Si X influye en M mediante la ruta "a" y M influye en Y mediante la ruta "b", el efecto indirecto corresponde a **a × b**. Esta estimación debe evaluarse mediante *bootstrapping*, porque la distribución del producto de dos coeficientes no suele cumplir supuestos de normalidad. Por ello, el análisis moderno de mediación no debe depender del enfoque clásico de pasos causales, que exige primero demostrar un efecto directo significativo entre X y Y. Ese requisito puede ser problemático, porque pueden existir efectos indirectos significativos aunque el efecto directo no lo sea. En PLS-SEM, lo más riguroso es evaluar directamente el intervalo de confianza del efecto indirecto: si el intervalo no incluye cero, existe evidencia empírica de mediación. **La clave no es preguntar primero si X afecta directamente a Y, sino si X transmite su influencia a través de M**. Esta lógica evita descartar mecanismos relevantes y permite interpretar modelos más acordes con la complejidad de los fenómenos organizacionales (Nitzl et al., 2016).

Una vez identificado el efecto indirecto, el investigador debe distinguir el tipo de mediación. Puede existir **mediación complementaria** cuando el efecto directo y el indirecto apuntan en la misma dirección; **mediación competitiva** cuando ambos efectos existen, pero tienen signos opuestos; **mediación solo indirecta** cuando el efecto indirecto es significativo y el directo no lo es; o **ausencia de mediación** cuando el efecto indirecto no alcanza significancia. Esta clasificación es importante porque evita interpretar toda mediación como si fuera igual. Una mediación complementaria sugiere que el antecedente influye en el resultado tanto de forma directa como a través del mecanismo. Una mediación competitiva puede revelar tensiones, efectos

compensatorios o relaciones más complejas. Una mediación solo indirecta indica que el antecedente opera principalmente mediante el mediador. **La mediación no debe reducirse a decir "sí hay" o "no hay"; debe explicar qué tipo de proceso estructural está ocurriendo**. En estudios administrativos, esta distinción permite formular discusiones más finas: no es lo mismo afirmar que la cultura innovadora incide directamente en el desempeño, que demostrar que su efecto se canaliza mediante aprendizaje, compromiso o capacidades dinámicas (Nitzl et al., 2016).

La mediación moderada debe incorporarse cuando el investigador no solo desea explicar cómo una variable independiente influye en una variable dependiente mediante un mediador, sino también si ese mecanismo cambia bajo determinadas condiciones. En una **mediación simple,** el interés se concentra en el efecto indirecto que conecta a la variable antecedente con la variable resultado a través de una variable mediadora; en cambio, en una mediación moderada, el efecto indirecto depende del nivel de un moderador. Esta lógica resulta especialmente útil en ciencias de la administración, porque muchos mecanismos organizacionales no operan de manera homogénea en todos los contextos. Por ejemplo, una capacidad organizacional puede influir en el desempeño mediante el aprendizaje, pero la fuerza de ese mecanismo puede variar según la turbulencia ambiental, la intensidad competitiva, la madurez digital o el tipo de organización. Por ello, la mediación moderada permite integrar mecanismo y condición en un mismo razonamiento estructural: explica cómo ocurre una relación y bajo qué circunstancias ese proceso se intensifica, se debilita o cambia de dirección. Su inclusión solo es pertinente cuando existe una justificación teórica previa, ya que añadir mediaciones moderadas sin fundamento puede producir modelos artificialmente complejos y difíciles de interpretar (Nitzl et al., 2016; Hair et al., 2021; Guenther et al., 2023).

En términos de reporte, la mediación moderada debe presentarse como evidencia de un efecto indirecto condicional. Esto implica distinguir entre el efecto directo, el efecto indirecto, el efecto total y la variación del efecto indirecto según el moderador. El investigador debe evitar interpretar por separado la mediación y la moderación cuando la hipótesis plantea que el mecanismo mediador depende de una condición específica. En ese caso, el análisis debe concentrarse en la estabilidad del efecto indirecto condicionado y en su coherencia con la teoría. **Así, la mediación moderada fortalece el modelo cuando permite explicar procesos administrativos complejos, pero debilita la investigación si se introduce solo como sofisticación estadística**. Su valor no reside en aumentar el número de relaciones, sino en mostrar que el mecanismo causal-predictivo del modelo depende de condiciones conceptualmente defendibles (Nitzl et al., 2016; Hair et al., 2019; Hair et al., 2021).

La moderación responde a una pregunta distinta de la mediación. Mientras la mediación explica el mecanismo, la moderación explica la condición: ¿cuándo, para quién o bajo qué circunstancias una relación cambia?. Una variable moderadora modifica la fuerza o dirección de la relación entre un antecedente y un resultado. Por ejemplo, la relación entre capacidades digitales e innovación puede ser más fuerte en entornos altamente competitivos; la relación entre liderazgo y

desempeño puede depender del clima organizacional; o el efecto de la confianza sobre la adopción tecnológica puede variar según la experiencia previa del usuario. La moderación es especialmente útil cuando la teoría sugiere que una relación no opera igual en todos los contextos. En PLS-SEM, los efectos moderadores permiten modelar interacciones y analizar si una variable condiciona la intensidad de una ruta estructural. **La moderación aporta valor cuando evita generalizaciones excesivas**. No todos los efectos son universales, lineales o constantes; algunos dependen de recursos, contextos, capacidades, presiones externas o características de los sujetos. Por ello, incluir una moderación requiere justificación conceptual sólida y no debe hacerse solo para aumentar complejidad estadística (Hair et al., 2021).

En los modelos PLS-SEM con moderación, el análisis no debe limitarse a afirmar que una variable condiciona la relación entre dos constructos; también debe especificarse cómo se construye y evalúa el término de interacción. El término de interacción representa el producto conceptual entre una variable antecedente y una variable moderadora, y permite estimar si la pendiente de la relación entre el predictor y la variable dependiente cambia en función del valor del moderador. En PLS-SEM, esta decisión debe ser coherente con la naturaleza de los constructos, el tipo de medición y el propósito explicativo-predictivo del modelo. Cuando el estudio trabaja con constructos compuestos, puntuaciones latentes o modelos complejos, resulta necesario justificar el procedimiento de generación del término de interacción y evaluar su efecto mediante *bootstrapping*, interpretando no solo la significancia estadística, sino también el signo, la magnitud y la relevancia sustantiva del coeficiente de interacción. De este modo, la moderación deja de ser una flecha adicional en el modelo y se convierte en una prueba explícita de contingencia teórica: la relación entre dos constructos no opera igual en todos los niveles o condiciones del moderador (Guenther et al., 2023).

En términos operativos, el investigador debe decidir cómo construirá el término de interacción. En PLS-SEM pueden utilizarse el enfoque del producto, el enfoque de dos etapas o la ortogonalización. El enfoque del producto genera indicadores multiplicando los indicadores de la variable independiente por los indicadores de la variable moderadora; el enfoque de dos etapas utiliza primero las puntuaciones latentes de los constructos y después calcula el producto entre ellas; y la ortogonalización busca reducir la colinealidad entre los efectos principales y el término de interacción. Cuando el modelo trabaja con constructos compuestos, puntuaciones latentes o estructuras complejas, el enfoque de dos etapas suele ser especialmente útil porque permite estimar la interacción de forma más parsimoniosa. La hipótesis de moderación se sostiene cuando el coeficiente del término de interacción es significativo, y su relevancia debe interpretarse junto con el tamaño del efecto y, cuando sea pertinente, mediante una gráfica de pendientes (Hair et al., 2021).

La diferencia entre mediación y moderación debe mantenerse con absoluta claridad. La mediación introduce una variable intermedia que transmite el efecto; la moderación introduce una variable que altera la relación entre dos constructos. En términos simples, **la mediación responde "cómo ocurre" y la moderación**

responde "cuándo ocurre o bajo qué condición cambia". Confundir ambas funciones puede debilitar el modelo y producir hipótesis mal formuladas. Por ejemplo, si se afirma que el aprendizaje organizacional explica el vínculo entre capacidades digitales e innovación, se está planteando una mediación. Pero si se afirma que la turbulencia ambiental fortalece o debilita ese vínculo, se está planteando una moderación. El error aparece cuando una variable se incorpora como mediadora sin representar un proceso intermedio, o como moderadora sin justificar por qué modificaría la intensidad de una relación. La especificación correcta depende del problema, la teoría y la lógica temporal del fenómeno. En PLS-SEM, esta diferenciación también afecta el análisis: la mediación se evalúa mediante efectos indirectos, mientras la moderación se evalúa mediante términos de interacción. **Cada efecto complejo requiere una lógica conceptual distinta y una estrategia estadística correspondiente** (Hair et al., 2019).

La mediación moderada, también entendida como mediación condicional, debe incorporarse cuando el investigador plantea que un efecto indirecto no es constante, sino que cambia según el valor de una variable moderadora. En una mediación simple, la variable independiente influye en la variable dependiente a través de un mediador; en una mediación moderada, ese mecanismo depende de una condición adicional. Por ello, el análisis no debe limitarse a probar por separado la mediación y la moderación, sino que debe estimar si el efecto indirecto varía de manera significativa según el moderador. En términos de interpretación, el interés central no está solo en saber si X influye en Y por medio de M, sino en determinar si esa influencia indirecta se fortalece, se debilita o cambia de dirección bajo distintos niveles de W. Esta lógica es especialmente pertinente en ciencias de la administración, donde los mecanismos organizacionales suelen depender del contexto, de los recursos, de la intensidad competitiva o de las características de los actores involucrados (Nitzl et al., 2016).

Los efectos complejos pueden incluir mediaciones múltiples, mediaciones en cadena, moderaciones simultáneas o modelos moderados-mediados. En una mediación múltiple, varios mediadores explican distintas rutas entre X y Y. En una mediación secuencial, X influye en M1, M1 influye en M2 y finalmente M2 influye en Y. En una moderación múltiple, diferentes variables condicionan distintas relaciones del modelo. En una mediación moderada, el efecto indirecto cambia dependiendo del nivel de una variable moderadora. Estas estructuras pueden ser poderosas para explicar fenómenos organizacionales, pero también aumentan la exigencia conceptual, muestral y analítica. **La complejidad solo debe incorporarse cuando mejora la explicación del fenómeno**, no cuando únicamente hace que el modelo parezca más avanzado. En estudios de administración, un exceso de efectos complejos puede generar modelos difíciles de interpretar, problemas de potencia estadística y discusiones fragmentadas. Por ello, antes de incorporar mediaciones o moderaciones múltiples, el investigador debe preguntarse si cada ruta es necesaria, si existe teoría que la respalde y si la muestra permite estimarla con estabilidad (Guenther et al., 2023).

En modelos PLS-SEM, la mediación también debe interpretarse en relación con la capacidad explicativa y predictiva del modelo. Un efecto indirecto puede mejorar la comprensión del fenómeno porque revela procesos internos, pero no necesariamente mejora la predicción fuera de muestra. Del mismo modo, una moderación puede aumentar la capacidad explicativa al mostrar condiciones bajo las cuales opera una relación, pero también puede aumentar la complejidad y afectar la estabilidad predictiva. Por ello, cuando se introducen efectos complejos, conviene revisar no solo significancia, sino también R^2, f^2, Q^2 y, cuando el objetivo lo justifique, PLSpredict. **Un modelo con mediaciones o moderaciones debe demostrar que su complejidad aporta valor analítico**. Si el modelo se vuelve más difícil de interpretar sin mejorar explicación, predicción o contribución teórica, la complejidad puede ser innecesaria. Esto refuerza la idea de que PLS-SEM no debe emplearse como herramienta para acumular relaciones, sino como estrategia para probar una arquitectura conceptual coherente, parsimoniosa y orientada a un propósito claro (Shmueli et al., 2019).

La evaluación de efectos complejos exige cuidar la potencia estadística. Una mediación simple ya implica estimar al menos dos rutas conectadas; una mediación múltiple o secuencial aumenta el número de parámetros; y una moderación agrega términos de interacción que suelen requerir mayor tamaño muestral para detectar efectos. Por ello, un modelo avanzado no puede justificarse solo por su atractivo teórico. Debe ser proporcional a la muestra disponible y al tamaño esperado de los efectos. **La complejidad estructural incrementa la exigencia empírica del modelo**, porque cada ruta adicional necesita información suficiente para ser estimada con estabilidad. Si la muestra es pequeña, los efectos indirectos o moderadores pueden aparecer como no significativos aunque existan en la población, o pueden estimarse con intervalos de confianza demasiado amplios. En PLS-SEM, la revisión del tamaño de muestra debe vincularse con la estructura del modelo, el número de predictores, la magnitud de los efectos y el poder estadístico requerido. Así, la mediación y la moderación deben incorporarse únicamente cuando el diseño empírico permite sostenerlas. **Un modelo complejo con baja potencia puede ser menos defendible que un modelo parsimonioso bien estimado** (Kock & Hadaya, 2018).

La moderación requiere especial cuidado porque el término de interacción no debe interpretarse de manera aislada. Cuando se estima una interacción, el investigador debe analizar si la relación entre X y Y cambia según el nivel de Z. Esto implica revisar el signo, magnitud y significancia del efecto moderador, pero también explicar conceptualmente qué significa ese cambio. Por ejemplo, si la turbulencia ambiental fortalece la relación entre capacidades digitales e innovación, la discusión debe mostrar por qué un entorno incierto vuelve más valiosas esas capacidades. **La moderación tiene sentido cuando permite explicar diferencias condicionales del fenómeno**, no cuando solo añade un coeficiente adicional al modelo. Además, conviene representar gráficamente el efecto cuando sea posible, porque la visualización ayuda a comprender si la pendiente aumenta, disminuye o cambia de dirección. En estudios administrativos, esta lectura es clave para traducir el resultado a implicaciones: no basta con afirmar que Z modera; debe decirse bajo qué condición

la relación se vuelve más intensa, más débil o incluso contradictoria. Por ello, la moderación exige teoría, estimación e interpretación sustantiva integradas (Hair et al., 2021).

Los efectos indirectos también requieren una interpretación cuidadosa del efecto total. El efecto total representa la suma del efecto directo y los efectos indirectos que conectan una variable antecedente con una variable resultado. En modelos con mediación, el efecto total puede revelar que una variable tiene mayor importancia de la que su efecto directo sugiere. Por ejemplo, una capacidad organizacional puede no influir directamente en el desempeño, pero sí hacerlo a través de aprendizaje, innovación o compromiso. **El efecto total ayuda a comprender la contribución global de un antecedente dentro del sistema estructural**. Sin embargo, no debe interpretarse mecánicamente: si el efecto directo y el indirecto tienen signos opuestos, puede existir mediación competitiva o supresión, lo que exige una discusión más fina. En estos casos, el investigador debe evitar simplificaciones como "la variable influye positivamente" si parte del sistema opera en sentido contrario. La interpretación robusta de la mediación requiere observar simultáneamente rutas directas, indirectas y totales, así como su coherencia teórica. De esta manera, el modelo puede explicar procesos más complejos sin perder claridad (Nitzl et al., 2016).

La incorporación de mediaciones y moderaciones debe relacionarse con la trazabilidad de hipótesis. Cada efecto complejo debe estar anticipado en el planteamiento teórico, formulado como hipótesis o proposición estructural, representado en el modelo gráfico, estimado en el análisis y discutido en los resultados. Si un mediador aparece en el diagrama pero no en la teoría, el modelo parece improvisado. Si una moderación se estima sin hipótesis previa, puede interpretarse como exploración, pero no como prueba confirmatoria. **La trazabilidad evita que los efectos complejos se conviertan en hallazgos oportunistas**. Para sostener rigor académico, el investigador debe mostrar el camino completo: vacío → teoría → relación → hipótesis → estimación → interpretación. Esto es especialmente importante porque los efectos complejos pueden generar muchas combinaciones posibles, y sin una lógica previa se corre el riesgo de seleccionar solo los resultados favorables. En PLS-SEM, la transparencia en el reporte protege contra interpretaciones sesgadas y permite que el lector evalúe si la complejidad responde a una necesidad científica real. Por ello, mediación y moderación deben estar integradas desde el diseño, no agregadas al final (Hair et al., 2019).

Los modelos con efectos complejos también deben cuidar la colinealidad. En moderación, los términos de interacción pueden estar asociados con sus componentes principales; en mediación, los predictores y mediadores pueden solaparse conceptualmente; y en modelos con varias variables cercanas puede aumentar la redundancia entre constructos. Si la colinealidad es elevada, la interpretación de efectos individuales se vuelve inestable, porque resulta difícil separar la contribución de cada variable. **Un efecto complejo mal especificado puede generar apariencia de sofisticación, pero esconder redundancia conceptual**. Por ejemplo, si "capacidad digital", "madurez digital" y "transformación digital" se incorporan como

antecedentes, mediadores o moderadores sin distinción precisa, el modelo puede mostrar problemas de VIF y validez discriminante. La solución no consiste solo en eliminar variables por criterio estadístico, sino en revisar la definición conceptual de cada constructo. En PLS-SEM, el control de colinealidad es indispensable para efectos complejos, porque las rutas indirectas, interacciones y efectos totales dependen de coeficientes interpretables. Un modelo complejo debe ser también conceptualmente limpio (Kock, 2015).

La invariancia de medición adquiere relevancia cuando los efectos complejos se comparan entre grupos. Si se quiere saber si una mediación funciona de forma diferente en empresas pequeñas y grandes, o si una moderación cambia entre sectores, primero debe comprobarse que los constructos se miden de manera equivalente. Sin invariancia, las diferencias observadas pueden deberse a que los grupos interpretan los indicadores de forma distinta. **Comparar efectos complejos sin verificar la equivalencia de medición puede producir conclusiones engañosas**. El procedimiento MICOM permite evaluar si los composites son comparables antes de realizar análisis multigrupo. Si se establece invariancia parcial, puede compararse la estructura de rutas; si se establece invariancia completa, pueden sostenerse comparaciones más amplias. Esto es esencial en estudios administrativos donde se comparan contextos, países, sectores, niveles de experiencia o tipos de organización. La mediación y la moderación pueden ser muy útiles para explicar diferencias, pero solo si las mediciones son equivalentes. Por tanto, la robustez de efectos complejos depende también de la calidad comparativa del modelo de medición (Henseler et al., 2016).

La predicción fuera de muestra ofrece otra forma de valorar si los efectos complejos aportan valor real. Un modelo con mediaciones y moderaciones puede explicar mejor el fenómeno, pero también puede sobreajustarse a la muestra. Por eso, cuando el estudio tiene orientación predictiva, conviene comparar si la incorporación de efectos complejos mejora la capacidad predictiva o solo aumenta la complejidad. **PLSpredict permite revisar si el modelo conserva utilidad frente a casos nuevos**, mediante indicadores como Q^2 _predict, RMSE y MAE. Si un modelo complejo no reduce los errores de predicción respecto a modelos más simples o de referencia, su valor práctico puede ser limitado. Esto no significa que deba eliminarse toda complejidad que no mejore predicción, porque algunos modelos buscan principalmente explicación teórica. Pero sí significa que el investigador debe alinear su interpretación con el propósito declarado. Si el estudio promete utilidad gerencial, la predicción debe evaluarse. Si el estudio busca mecanismos explicativos, la contribución puede estar en la comprensión del proceso. La robustez exige distinguir ambos planos (Shmueli et al., 2019).

Los efectos complejos también requieren una discusión explícita sobre endogeneidad. En una mediación, por ejemplo, puede existir causalidad inversa entre mediador y variable dependiente, o una variable omitida puede explicar simultáneamente al mediador y al resultado. En una moderación, la variable moderadora puede estar asociada con factores no observados que afecten la relación

principal. **Si existe endogeneidad, los efectos indirectos, directos o moderadores pueden estar sesgados**, lo que debilita la interpretación causal del modelo. Por ello, cuando el estudio pretende explicar relaciones estructurales, el investigador debe preguntarse si hay variables omitidas relevantes, simultaneidad, error de medición o heterogeneidad no observada. En PLS-SEM pueden utilizarse variables de control, variables instrumentales o cópulas gaussianas, según la disponibilidad de datos y el diseño. Cuando no sea posible corregir el problema, debe reconocerse como limitación. La robustez no exige resolver todas las amenazas, pero sí identificarlas y discutirlas con prudencia. Un modelo con mediación o moderación será más defendible si reconoce los límites de sus inferencias (Hult et al., 2018).

En el reporte académico, los efectos complejos deben presentarse con claridad y sin exceso de tecnicismo innecesario. Para mediación, conviene reportar rutas componentes, efecto indirecto, efecto directo, efecto total, intervalo de confianza y tipo de mediación. Para moderación, deben reportarse efecto principal, término de interacción, significancia, tamaño del efecto y, si es útil, gráfica de pendientes. Para modelos complejos, debe explicarse qué hipótesis corresponde a cada ruta y qué conclusión se deriva. **El lector debe poder identificar qué efecto fue probado, cómo fue estimado y qué significa dentro del modelo**. El reporte no debe limitarse a tablas; debe traducir resultados en explicación. Por ejemplo, no basta con decir que el efecto indirecto fue significativo; debe explicarse qué mecanismo confirma. Tampoco basta con decir que la interacción fue significativa; debe aclararse bajo qué condiciones la relación cambia. Esta forma de reporte fortalece la contribución científica, porque conecta resultados estadísticos con argumentos teóricos y aplicaciones administrativas (Hair et al., 2019).

La mediación, la moderación y los efectos complejos deben cerrar con una lógica de parsimonia avanzada. La parsimonia no significa evitar complejidad, sino incorporar únicamente la complejidad necesaria para responder mejor la pregunta de investigación. Un modelo con una mediación bien justificada puede ser más sólido que un modelo con múltiples moderaciones débiles. Un modelo con una interacción teóricamente central puede aportar más que una red saturada de efectos indirectos. **La complejidad es valiosa solo cuando aumenta explicación, predicción, diferenciación contextual o contribución teórica**. En PLS-SEM, la flexibilidad del método facilita estimar modelos amplios, pero esa flexibilidad debe acompañarse de disciplina conceptual. Cada efecto complejo debe responder a una razón: explicar un mecanismo, delimitar una condición, comparar grupos, mejorar predicción o fortalecer la contribución. Si no cumple ninguna de estas funciones, debe eliminarse. Así, los efectos complejos dejan de ser adornos estadísticos y se convierten en herramientas para comprender fenómenos administrativos con mayor profundidad, rigor y utilidad científica (Guenther et al., 2023).

En la literatura sobre mediación moderada, los números de modelo funcionan como una clasificación convencional de configuraciones analíticas. No representan tipos distintos de PLS-SEM, niveles de dificultad ni una secuencia obligatoria que deba revisarse completa. Cada número identifica **dónde se ubica el**

moderador dentro del proceso indirecto que conecta una variable independiente, una variable mediadora y una variable dependiente. Por ello, el investigador no debe memorizar los números como si fueran categorías aisladas, sino comprender qué parte del mecanismo mediador cambia por efecto de una condición moderadora (Hayes, 2015; Cheah et al., 2021).

En una mediación simple, la lógica básica es **X** → **M** → **Y**. La variable **X** influye en la variable **Y** por medio de una variable mediadora **M**. En una mediación moderada, se agrega una variable **W** que modifica la fuerza, tamaño o dirección de ese efecto indirecto. Dicho de otro modo, la pregunta deja de ser únicamente "¿X influye en Y a través de M?" y pasa a ser: **¿ese efecto indirecto cambia según el nivel o la condición representada por W?** Esta lógica coincide con el análisis de mediación condicional, que combina mediación y moderación para comprobar si una relación mediada cambia por contexto, límites o diferencias individuales.

La clasificación más útil para fines aplicados distingue entre configuraciones básicas y configuraciones complejas. En el **Modelo 7**, el moderador se ubica en el primer tramo de la mediación, es decir, en la relación **X** → **M**. En el **Modelo 14**, el moderador se ubica en el segundo tramo, es decir, en la relación **M** → **Y**. En el **Modelo 58**, el moderador afecta ambos tramos del proceso indirecto. En el **Modelo 21**, existen condiciones moderadoras múltiples. En el **Modelo 74**, la configuración implica una interacción específica dentro del camino indirecto. Lo importante no es el número en sí mismo, sino **la posición conceptual del moderador** y su efecto sobre el camino indirecto completo (Cheah et al., 2021). Véase la **Tabla 6.1**

Tabla 6.1. Clasificación de modelos de mediación moderada según la ubicación del moderador

Clasificación	Ubicación del moderador	Lectura conceptual
Modelo 7	**X → M**	El moderador cambia el primer tramo de la mediación.
Modelo 14	**M → Y**	El moderador cambia el segundo tramo de la mediación.
Modelo 58	**X → M** y **M → Y**	El moderador cambia ambos tramos del efecto indirecto.
Modelo 21	Más de un moderador	La mediación depende de varias condiciones.
Modelo 74	Interacción específica dentro del camino indirecto	El efecto indirecto cambia por una interacción particular.

Fuente: recopilación y elaboración propia

El **Modelo 7** debe entenderse como la situación en la que el moderador cambia la relación entre la variable independiente y la mediadora. Por ejemplo, si **capacidades digitales** influyen en **aprendizaje organizacional**, y este aprendizaje influye después en **desempeño innovador**, el Modelo 7 se presenta cuando una condición, como la **turbulencia ambiental**, modifica la fuerza de la relación entre capacidades digitales y aprendizaje organizacional. En este caso, el investigador pregunta si las capacidades digitales generan más o menos aprendizaje según el nivel de turbulencia del entorno.

En términos operativos, el índice de mediación moderada del Modelo 7 se expresa como **p5 · p2**, y si ese índice es significativo, puede afirmarse que el efecto indirecto está moderado.

El **Modelo 14** se presenta cuando el moderador cambia la relación entre la mediadora y la variable dependiente. Siguiendo el ejemplo anterior, las capacidades digitales pueden influir en el aprendizaje organizacional, pero el efecto del aprendizaje sobre el desempeño innovador puede depender de una condición adicional, como la **cultura innovadora**. En este caso, el investigador no pregunta si la mediación existe de manera uniforme, sino si el aprendizaje organizacional se traduce en mayor desempeño innovador bajo ciertos niveles de cultura innovadora. En esta configuración, el índice de mediación moderada se expresa como **p5 · p1**, y su significancia indica que el segundo tramo del efecto indirecto está condicionado por el moderador.

Los modelos más complejos deben mencionarse solo cuando aporten claridad al diseño. El **Modelo 58** considera que el moderador puede afectar tanto el primer como el segundo tramo del proceso mediador, por lo que el índice puede expresarse como **p2 · p5 + p1 · p7**. El **Modelo 21** incorpora mediación moderada múltiple, es decir, más de una condición moderadora en el efecto indirecto. El **Modelo 74** representa una configuración específica en la que la interacción altera el camino indirecto mediante una forma distinta de combinación entre variables. Estos modelos pueden ser útiles en investigaciones avanzadas, pero deben evitarse si no existe una justificación teórica fuerte, una muestra suficiente y una estrategia clara de reporte.

Los números de modelo utilizados en mediación moderada funcionan como una **clasificación convencional de configuraciones analíticas**. Cada número identifica **dónde se ubica el moderador** dentro del proceso indirecto. Por ejemplo, el **Modelo 7** ubica el moderador en el tramo **X → M**, mientras que el **Modelo 14** lo ubica en el tramo **M → Y**. En modelos más complejos, como el **Modelo 58**, el moderador puede afectar ambos tramos del efecto indirecto; en el **Modelo 21**, pueden intervenir condiciones moderadoras múltiples; y en el **Modelo 74**, la interacción modifica una configuración específica del camino indirecto (Hayes, 2015; Cheah et al., 2021).

Para reportar la mediación moderada en PLS-SEM, el investigador debe estimar el modelo con el término de interacción correspondiente, ejecutar ***bootstrapping***, recuperar los coeficientes *path* implicados en el índice, calcular el producto o combinación de productos pertinente y evaluar el **intervalo de confianza percentil**. Si el intervalo de confianza del índice de mediación moderada no incluye cero, existe evidencia de un efecto indirecto condicionado. Si el índice no es significativo, deben reportarse la mediación y la moderación por separado, sin afirmar mediación moderada. Este procedimiento evita interpretar aisladamente una interacción y obliga a evaluar su efecto sobre el mecanismo indirecto completo. Váse la **Tabla 6.2**

Tabla 6.2. Procedimiento para evaluar y reportar la mediación moderada en PLS-SEM

Paso	Acción	Resultado esperado
1	Identificar si el moderador afecta **X** → **M**, **M** → **Y** o ambos tramos.	Elegir la configuración adecuada.
2	Justificar teóricamente por qué el efecto indirecto debería cambiar.	Evitar complejidad estadística artificial.
3	Estimar el modelo con el término de interacción.	Obtener coeficientes *path*.
4	Ejecutar ***bootstrapping***.	Generar intervalos de confianza.
5	Calcular el índice de mediación moderada.	Evaluar si el efecto indirecto condicionado es significativo.
6	Revisar si el intervalo incluye cero.	Si no incluye cero, hay mediación moderada.
7	Reportar interpretación sustantiva.	Explicar cómo y bajo qué condición cambia el mecanismo.

Fuente: recopilación y elaboración propia

En síntesis, la clasificación de modelos de mediación moderada debe usarse como una herramienta de lectura conceptual. Su función no es multiplicar modelos, sino ayudar al investigador a precisar **qué parte del proceso indirecto está condicionada**. En PLS-SEM aplicado, basta con dominar primero el **Modelo 7** y el **Modelo 14**, porque representan las dos ubicaciones básicas del moderador: antes del mediador o después del mediador. Las configuraciones más complejas solo deben incorporarse cuando el problema de investigación, la teoría y la evidencia empírica lo justifiquen. Para estimar la mediación moderada en PLS-SEM, el investigador debe ejecutar ***bootstrapping***, recuperar los coeficientes *path* implicados, calcular el producto o combinación de productos correspondiente al índice de mediación moderada y revisar si el intervalo de confianza incluye el cero. Si el intervalo no incluye cero, existe evidencia de **efecto indirecto condicionado**; si incluye cero, deben reportarse mediación y moderación por separado (Cepeda Carrión et al., 2017; Cheah et al., 2021).

Invariancia y análisis multigrupo en PLS-SEM

La invariancia y el análisis multigrupo constituyen una etapa avanzada de PLS-SEM porque permiten evaluar si un modelo funciona de manera equivalente en distintos grupos de observaciones. En ciencias de la administración, esta necesidad aparece cuando el investigador desea comparar hombres y mujeres, estudiantes de licenciatura y posgrado, pymes y grandes empresas, sectores industriales, países, regiones, generaciones, niveles de experiencia o usuarios con distinta intensidad tecnológica. Sin embargo, comparar grupos no significa únicamente dividir la muestra y observar si los coeficientes *path* son diferentes. Antes de interpretar diferencias estructurales, debe comprobarse si los constructos conservan un significado comparable entre los grupos. Si un constructo como confianza, capacidad digital, aprendizaje organizacional, innovación o compromiso se interpreta de manera distinta en cada grupo, entonces cualquier diferencia en los coeficientes puede ser

engañosa. **La invariancia de medición protege la validez de las comparaciones**, porque evita confundir diferencias reales en relaciones estructurales con diferencias originadas por la forma en que cada grupo entiende o responde los indicadores. Por ello, el análisis multigrupo debe verse como una extensión del modelo estructural, pero también como una prueba de calidad del modelo de medición. Sin invariancia, la comparación puede parecer estadísticamente atractiva, pero metodológicamente débil. En PLS-SEM, esta revisión es especialmente relevante porque el método trabaja con composites y constructos estimados a partir de indicadores, por lo que la equivalencia entre grupos debe demostrarse antes de sostener conclusiones comparativas (Henseler et al., 2016).

El análisis multigrupo responde a una pregunta sustantiva: ¿las relaciones del modelo son iguales o diferentes entre grupos? Esta pregunta no debe formularse por curiosidad estadística, sino por una razón teórica, contextual o práctica. Por ejemplo, puede tener sentido comparar pymes y grandes empresas si se espera que los recursos organizacionales modifiquen la relación entre capacidades digitales e innovación. También puede ser pertinente comparar estudiantes de licenciatura y posgrado si se supone que la experiencia académica cambia la relación entre autoeficacia tecnológica y adopción de inteligencia artificial. De igual modo, puede justificarse comparar países o regiones cuando existen diferencias culturales, institucionales o de madurez tecnológica. **La comparación multigrupo debe surgir del problema de investigación**, no de la disponibilidad accidental de una variable categórica. Si el investigador divide la muestra sin una hipótesis clara, corre el riesgo de producir resultados fragmentados y poco interpretables. Además, cada comparación exige suficiente tamaño muestral por grupo y criterios de medición equivalentes. En este sentido, el análisis multigrupo no es un procedimiento automático, sino una decisión metodológica que debe justificarse en la teoría, en el contexto y en la lógica del modelo estructural. La robustez de una comparación depende de que el investigador pueda explicar por qué esos grupos podrían diferir y qué implicaría encontrar diferencias o similitudes en las rutas del modelo (Hair et al., 2019).

La invariancia de medición significa que el instrumento mide el mismo constructo de manera comparable en distintos grupos. En términos prácticos, implica que los indicadores, la estructura de medición, el tratamiento de datos y la formación de los composites sean suficientemente equivalentes para que las diferencias observadas puedan atribuirse al fenómeno y no al instrumento. Por ejemplo, si un ítem sobre “uso avanzado de tecnologías digitales” tiene un significado distinto para estudiantes, directivos o emprendedores, entonces el constructo puede no ser comparable. Lo mismo ocurre si una escala traducida a distintos idiomas no conserva el mismo sentido semántico, o si los grupos presentan patrones de respuesta muy diferentes por razones culturales o contextuales. **La invariancia es una condición previa para comparar**, porque sin ella se corre el riesgo de interpretar como diferencia estructural lo que en realidad es diferencia de medición. En modelos basados en composites, el procedimiento MICOM fue diseñado precisamente para valorar esta equivalencia en PLS-SEM. Su importancia radica en que las técnicas

tradicionales de invariancia, asociadas con modelos de factor común, no se trasladan directamente a modelos compuestos. Por ello, cuando se trabaja con PLS-SEM y se desea realizar análisis multigrupo, la evaluación de invariancia debe adaptarse a la naturaleza del método y de sus constructos estimados (Henseler et al., 2016).

El procedimiento MICOM evalúa la invariancia de medición de composites mediante tres pasos jerárquicos: invariancia configural, invariancia composicional e igualdad de medias y varianzas. La **invariancia configural** exige que el modelo esté especificado de la misma manera en todos los grupos. Esto incluye usar los mismos indicadores por constructo, el mismo tratamiento de datos, la misma codificación, el mismo algoritmo y los mismos criterios de estimación. Si un grupo responde una versión distinta del instrumento, si se eliminan indicadores en un grupo pero no en otro, o si los datos se procesan de manera diferente, la comparación pierde fundamento. La **invariancia composicional** evalúa si los composites se forman de manera equivalente entre los grupos, es decir, si la combinación de indicadores produce constructos comparables. Finalmente, la igualdad de medias y varianzas permite determinar si existe invariancia completa y si es posible comparar niveles de constructos, además de relaciones estructurales. **MICOM no es un trámite estadístico; es una defensa metodológica de la comparación**. Si se cumplen los dos primeros pasos, puede hablarse de invariancia parcial y, por tanto, comparar coeficientes estructurales con mayor seguridad. Si se cumplen los tres, existe una base más fuerte para comparaciones más amplias. Esta secuencia evita que el análisis multigrupo se base solo en diferencias aparentes entre coeficientes *path* (Henseler et al., 2016).

La invariancia configural es el primer filtro de calidad y tiene una naturaleza principalmente conceptual y procedimental. Su propósito es asegurar que el modelo se construyó igual para todos los grupos antes de estimar diferencias. En esta fase, el investigador debe confirmar que cada constructo tiene los mismos indicadores en cada grupo, que las escalas de respuesta son equivalentes, que la codificación se aplicó de forma idéntica, que los valores perdidos se trataron con el mismo criterio y que el algoritmo de PLS-SEM se ejecutó bajo la misma configuración. **Si la estructura básica del modelo cambia entre grupos, la comparación deja de ser interpretable**. Por ejemplo, no sería adecuado comparar la relación entre liderazgo e innovación en dos grupos si en uno de ellos el constructo liderazgo tiene cinco indicadores y en otro solo tres, salvo que se justifique y se reevalúe cuidadosamente la equivalencia. Tampoco sería válido comparar grupos si una escala fue adaptada culturalmente sin verificar que conserva el mismo contenido. La invariancia configural obliga al investigador a revisar la trazabilidad del instrumento y del procesamiento de datos. En este sentido, es una etapa que conecta el capítulo de medición con el análisis avanzado: antes de comparar rutas, se debe demostrar que los datos fueron construidos bajo condiciones equivalentes. Por eso, la invariancia configural es la base mínima para cualquier análisis multigrupo responsable (Hair et al., 2021).

La invariancia composicional constituye el segundo paso del procedimiento MICOM y es especialmente relevante en PLS-SEM porque el método forma

composites como combinaciones ponderadas de indicadores. Esta etapa evalúa si el composite se forma de manera equivalente en los grupos comparados. En otras palabras, no basta con que los indicadores sean los mismos; también debe verificarse que su combinación genere una entidad comparable. Si los pesos o la composición del constructo difieren sustancialmente entre grupos, el significado empírico del composite puede cambiar. Por ejemplo, la "capacidad digital" podría estar formada principalmente por habilidades analíticas en un grupo, pero por infraestructura tecnológica en otro. En ese caso, aunque el constructo tenga el mismo nombre, no estaría representando exactamente lo mismo. **La invariancia composicional permite comprobar si el constructo conserva su arquitectura empírica entre grupos**. Esta prueba suele realizarse mediante procedimientos de permutación, que comparan la correlación entre los puntajes compuestos obtenidos con distintas configuraciones. Si se confirma la invariancia composicional, el investigador puede avanzar hacia comparaciones estructurales con mayor confianza. Si no se confirma, las diferencias en las rutas podrían deberse a que los constructos no se forman igual en los grupos. Por ello, este paso es central para evitar inferencias equivocadas en investigaciones comparativas (Henseler et al., 2016).

El tercer paso de MICOM evalúa la igualdad de medias y varianzas de los composites entre grupos. Esta etapa no siempre es necesaria para comparar coeficientes estructurales, pero sí resulta importante cuando el investigador desea comparar niveles promedio de constructos o interpretar diferencias más amplias entre grupos. Si se cumplen la invariancia configural y composicional, se establece invariancia parcial, suficiente para comparar relaciones estructurales. Si además se cumplen igualdad de medias y varianzas, se puede hablar de invariancia completa. **La invariancia completa ofrece una base más fuerte para sostener comparaciones entre grupos**, porque indica que los composites no solo se forman de manera similar, sino que sus distribuciones son comparables. Esto puede ser relevante, por ejemplo, si se desea comparar el nivel promedio de autoeficacia digital entre estudiantes de licenciatura y posgrado, o el nivel de innovación entre pymes y grandes empresas. Sin embargo, si no se cumple igualdad de medias o varianzas, esto no invalida automáticamente la comparación de rutas estructurales, siempre que exista invariancia parcial. La clave está en interpretar correctamente el nivel de invariancia alcanzado. El investigador debe reportar con claridad si cuenta con invariancia parcial o completa y qué tipo de conclusiones puede sostener. Así, MICOM no solo produce resultados técnicos, sino que delimita el alcance de la comparación (Henseler et al., 2016).

Una vez evaluada la invariancia, el análisis multigrupo permite comparar si los coeficientes *path* difieren significativamente entre grupos. Esto puede aplicarse a relaciones directas, efectos indirectos, efectos moderadores, R^2 o incluso resultados predictivos, siempre que el diseño lo justifique. En PLS-SEM, las comparaciones multigrupo pueden realizarse mediante enfoques como PLS-MGA, pruebas de permutación o pruebas paramétricas, dependiendo de las condiciones del estudio. **El objetivo no es solo detectar diferencias estadísticas, sino interpretar diferencias estructurales con sentido teórico**. Por ejemplo, si la relación entre confianza y adopción tecnológica es más fuerte en usuarios expertos que en usuarios

principiantes, el hallazgo debe explicarse desde la experiencia, la reducción de incertidumbre o la familiaridad con la tecnología. Si la relación entre liderazgo e innovación es más intensa en empresas grandes que en pymes, debe discutirse en función de recursos, formalización o capacidades organizacionales. La comparación multigrupo agrega valor cuando muestra que el modelo no opera igual para todos, pero debe evitarse convertir cada diferencia en una conclusión relevante. El investigador debe distinguir entre diferencia estadística, diferencia sustantiva y diferencia teóricamente significativa. Solo cuando estos tres niveles convergen, el análisis multigrupo fortalece la contribución del estudio (Hair et al., 2019).

El análisis multigrupo puede enriquecerse cuando el investigador no solo compara la fuerza de las relaciones estructurales, sino también las condiciones necesarias que podrían variar entre grupos. Después de verificar la invariancia de medición y comparar coeficientes mediante MGA, puede analizarse si ciertos antecedentes funcionan como condiciones mínimas en un grupo, pero no en otro. Esta lectura es útil porque dos grupos pueden presentar coeficientes estructurales similares y, aun así, diferir en los niveles mínimos requeridos para alcanzar un resultado alto. Por ejemplo, la capacidad digital puede ser una condición necesaria para lograr alto desempeño innovador en empresas grandes, pero no necesariamente en microempresas; o la cultura innovadora puede ser indispensable en sectores intensivos en conocimiento, pero menos necesaria en sectores tradicionales. Así, la comparación multigrupo no solo informa si una relación es más fuerte o más débil, sino si los grupos requieren **umbrales mínimos distintos** para lograr el mismo resultado. Esta integración mejora la interpretación contextual porque evita formular recomendaciones universales cuando las condiciones de éxito dependen del grupo analizado (Richter et al., 2020; Henseler et al., 2016).

El análisis multigrupo en PLS-SEM debe interpretarse como una extensión del modelo estructural, no como un ejercicio aislado de comparación estadística. Una vez establecida la invariancia mínima necesaria, el investigador puede examinar si las relaciones entre constructos se comportan de forma diferente entre grupos. Sin embargo, **una diferencia entre coeficientes *path* solo tiene valor científico si responde a una hipótesis, a una expectativa teórica o a una condición contextual relevante**. Por ejemplo, comparar estudiantes de licenciatura y posgrado puede ser pertinente si se espera que la experiencia académica modifique la relación entre autoeficacia y adopción tecnológica; comparar pymes y grandes empresas puede ser útil si se supone que los recursos organizacionales alteran la relación entre capacidades digitales e innovación. En cambio, dividir la muestra por variables disponibles, pero sin fundamento, puede producir hallazgos fragmentados. El análisis multigrupo debe responder una pregunta: ¿el modelo opera igual para todos o existen diferencias estructurales relevantes? Si la respuesta muestra diferencias, estas deben discutirse como variaciones del fenómeno, no solo como cambios numéricos. **La comparación multigrupo fortalece la explicación cuando ayuda a delimitar el alcance del modelo y a identificar condiciones bajo las cuales sus relaciones cambian** (Hair et al., 2019).

Una primera regla de interpretación consiste en distinguir entre diferencia estadística y diferencia sustantiva. En muestras grandes, una diferencia pequeña entre coeficientes puede resultar significativa, pero tener escasa relevancia práctica. En muestras pequeñas, una diferencia aparentemente importante puede no alcanzar significancia por falta de potencia estadística. Por ello, el investigador no debe limitarse a decir que una ruta "es diferente" entre grupos. Debe evaluar la magnitud de los coeficientes, su dirección, su significancia, sus intervalos de confianza y su coherencia con la teoría. **Una diferencia multigrupo es relevante cuando modifica la comprensión del fenómeno**, permite explicar comportamientos diferenciados o genera implicaciones prácticas útiles. Por ejemplo, si el efecto de la confianza sobre la intención de adopción es mucho mayor en usuarios con experiencia, la discusión puede señalar que la confianza actúa de manera distinta según el nivel de familiaridad tecnológica. Pero si la diferencia es mínima, aunque estadísticamente significativa, conviene interpretarla con cautela. La robustez del análisis multigrupo exige evitar conclusiones exageradas y reconocer que la significancia no equivale automáticamente a importancia teórica, administrativa o predictiva (Guenther et al., 2023).

La comparación de grupos también puede aplicarse a efectos indirectos. Esto es importante cuando el investigador sospecha que un mecanismo mediador funciona de manera diferente entre submuestras. Por ejemplo, el aprendizaje organizacional puede mediar con mayor fuerza la relación entre capacidades digitales e innovación en empresas con cultura colaborativa que en empresas jerárquicas. De igual modo, la reducción de riesgo puede mediar más intensamente la relación entre confianza e intención de adopción en usuarios principiantes que en usuarios expertos. **Comparar mediaciones entre grupos permite identificar mecanismos diferenciados**, no solo diferencias en rutas directas. Para hacerlo correctamente, deben revisarse los efectos indirectos por grupo y sus intervalos de confianza, además de evaluar si las diferencias entre efectos indirectos son significativas. Esto requiere una muestra suficiente en cada grupo y una base conceptual clara. Si el mediador no tiene el mismo significado entre grupos, la comparación pierde validez. Por ello, la invariancia es indispensable antes de comparar procesos. En PLS-SEM, esta lógica ayuda a evitar interpretaciones simplistas: un antecedente puede influir en el resultado por mecanismos distintos según el contexto, el perfil de los sujetos o las condiciones organizacionales (Nitzl et al., 2016).

El análisis multigrupo también se relaciona con la moderación categórica. Cuando el investigador divide la muestra en grupos, la variable de agrupación puede entenderse como una condición que modifica la relación entre constructos. En este sentido, comparar coeficientes entre grupos es una forma de evaluar si una relación está condicionada por pertenecer a una categoría específica. Por ejemplo, si la relación entre liderazgo transformacional y compromiso es más fuerte en equipos virtuales que en equipos presenciales, el tipo de equipo opera como condición moderadora. **La diferencia entre grupos puede interpretarse como evidencia de que el contexto cambia la intensidad de una relación estructural**. Sin embargo, esta interpretación debe hacerse con cuidado. No toda diferencia multigrupo equivale a una moderación

teóricamente relevante. La variable de agrupación debe tener sentido conceptual y estar vinculada con la relación que se compara. Además, conviene no multiplicar comparaciones sin control, porque se incrementa el riesgo de encontrar diferencias espurias. El análisis multigrupo aporta valor cuando permite demostrar que ciertas relaciones son más fuertes, más débiles o incluso opuestas bajo condiciones claramente justificadas (Hair et al., 2021).

Un aspecto importante es que la comparación multigrupo puede revelar equifinalidad o heterogeneidad estructural. En administración, distintos grupos pueden llegar a resultados similares mediante rutas diferentes. Por ejemplo, en empresas grandes, la innovación puede depender más de capacidades formales de investigación y desarrollo, mientras que en pymes puede depender más de aprendizaje informal o flexibilidad organizacional. En ambos casos puede existir desempeño innovador, pero los caminos explicativos son distintos. **El análisis multigrupo permite mostrar que un mismo resultado puede producirse mediante estructuras causales diferenciadas**. Esta idea ayuda a evitar generalizaciones excesivas y mejora la utilidad práctica del modelo. Si el investigador demuestra que un modelo opera de manera distinta en contextos específicos, las recomendaciones pueden adaptarse mejor a cada grupo. No obstante, esta lectura exige prudencia: las diferencias deben estar apoyadas por teoría, evidencia empírica y suficiente calidad de medición. Si no se verifica invariancia, la aparente heterogeneidad puede ser solo un artefacto de medición. Por ello, la comparación multigrupo debe articularse siempre con la evaluación de equivalencia de los constructos (Henseler et al., 2016).

La estabilidad del análisis multigrupo depende también del tamaño de muestra por grupo. No basta con que la muestra total sea adecuada; cada subgrupo debe contar con observaciones suficientes para estimar el modelo con estabilidad. Una muestra total amplia puede volverse limitada si se divide en demasiadas categorías. Por ejemplo, un estudio con 300 casos puede ser razonable para el modelo general, pero si se divide en cinco grupos, algunos segmentos pueden quedar con tamaño insuficiente. **Cada comparación reduce la información disponible por grupo y aumenta la exigencia de potencia estadística**. Esto es especialmente crítico cuando el modelo tiene muchas rutas, mediaciones, moderaciones o constructos con varios indicadores. El investigador debe evitar segmentaciones excesivas y privilegiar comparaciones centrales para la pregunta de investigación. Cuando los grupos son pequeños, los intervalos de confianza pueden ampliarse y las diferencias pueden ser inestables. Por ello, la decisión de realizar análisis multigrupo debe planearse desde el diseño, no improvisarse al final. La comparación será más robusta cuando los grupos fueron definidos previamente, tienen fundamento teórico y cuentan con tamaño muestral suficiente (Kock & Hadaya, 2018).

El análisis multigrupo también exige revisar la calidad de los modelos de medición dentro de cada grupo. Aunque el modelo general cumpla criterios de confiabilidad, validez convergente y validez discriminante, es posible que un constructo funcione adecuadamente en un grupo y de manera débil en otro. Por ejemplo, una escala de capacidad digital puede mostrar buenas cargas en empresas tecnológicas,

pero menor consistencia en organizaciones con baja madurez digital. **Antes de comparar relaciones estructurales, debe confirmarse que los constructos tienen calidad aceptable en cada grupo**. Esto implica revisar cargas externas, confiabilidad, AVE, HTMT y VIF cuando corresponda. Si un constructo tiene medición deficiente en un grupo, la diferencia estructural podría reflejar ruido de medición. Esta revisión es particularmente importante en modelos con composites, porque la forma en que los indicadores contribuyen al constructo puede variar según el grupo. La evaluación por submuestras no debe verse como repetición innecesaria, sino como garantía de que la comparación se apoya en constructos empíricamente defendibles. Un análisis multigrupo sólido depende tanto de la estructura como de la calidad de medición en cada segmento (Hair et al., 2021).

En términos de reporte, el análisis multigrupo debe presentarse de forma ordenada, trazable y proporcional. El investigador debe indicar primero por qué los grupos fueron seleccionados, después reportar la evaluación de invariancia y finalmente presentar las diferencias estructurales relevantes. Una secuencia adecuada sería: justificación teórica de la comparación, descripción del tamaño de cada grupo, resultados de MICOM, comparación de coeficientes *path*, interpretación sustantiva y límites de la comparación. **No conviene presentar primero las diferencias de rutas sin haber explicado la equivalencia de medición**, porque eso debilita la defensa metodológica del análisis. Además, las tablas deben ser claras: coeficiente por grupo, diferencia entre coeficientes, valor p o intervalo, y decisión interpretativa. La narrativa debe evitar saturar al lector con todas las diferencias posibles. Se deben destacar solo aquellas que responden a hipótesis o aportan sentido al fenómeno. Un reporte multigrupo robusto no es el que muestra más tablas, sino el que permite comprender qué se comparó, por qué se comparó, si era válido compararlo y qué significa la diferencia observada (Hair et al., 2019).

La interpretación de resultados multigrupo debe evitar el determinismo categorial. Encontrar diferencias entre grupos no significa que todos los miembros de un grupo se comporten igual ni que la categoría explique por completo el fenómeno. Por ejemplo, si se encuentra que el efecto de la autoeficacia sobre la adopción tecnológica es más fuerte en estudiantes de posgrado, no debe afirmarse que “los estudiantes de posgrado adoptan tecnología por autoeficacia” de manera absoluta. La categoría indica una diferencia promedio en una relación estructural, no una regla universal. **La comparación multigrupo debe interpretarse como variación probabilística y contextual**, no como etiqueta rígida. Esta prudencia es importante para evitar conclusiones simplistas o estereotipadas. En ciencias de la administración, los grupos suelen ser heterogéneos internamente; por ello, las diferencias deben leerse como tendencias estructurales bajo ciertas condiciones. Además, si la variable de agrupación es amplia, puede ocultar subgrupos internos. La robustez interpretativa requiere reconocer estos límites y evitar atribuir a la categoría más poder explicativo del que realmente tiene (Shmueli et al., 2019).

El análisis multigrupo puede complementar, pero no sustituir, otros enfoques de heterogeneidad no observada. Cuando los grupos se definen a priori, el

investigador compara categorías conocidas: género, país, tipo de empresa, nivel educativo o sector. Sin embargo, puede existir heterogeneidad que no coincide con esas categorías visibles. Por ejemplo, dentro de un mismo sector pueden existir empresas orientadas a eficiencia y empresas orientadas a innovación; dentro de un grupo de estudiantes puede haber segmentos con alta y baja experiencia digital. **Si la heterogeneidad relevante no está observada, dividir la muestra por categorías superficiales puede no revelar las verdaderas diferencias estructurales**. En estos casos, pueden considerarse procedimientos complementarios de segmentación o análisis de clases latentes, si el diseño y la muestra lo permiten. Sin embargo, el capítulo debe mantener el foco: el análisis multigrupo es más sólido cuando los grupos están definidos teóricamente. La heterogeneidad no observada debe mencionarse como una posibilidad que amplía la agenda metodológica, no como una obligación para todo estudio. Lo esencial es que el investigador reconozca que la muestra total puede ocultar patrones diferenciados (Guenther et al., 2023).

Finalmente, la invariancia y el análisis multigrupo fortalecen la contribución científica porque permiten delimitar para quién, en qué contexto y bajo qué condiciones funciona el modelo. Un modelo general puede mostrar que ciertas capacidades influyen en un resultado; un análisis multigrupo puede mostrar que esa influencia es más fuerte en un tipo de organización, más débil en otro o incluso no significativa en ciertos contextos. Esta información incrementa el valor teórico y práctico del estudio. Teóricamente, ayuda a precisar el alcance de las relaciones; prácticamente, permite formular recomendaciones diferenciadas. **La verdadera utilidad del análisis multigrupo no está en encontrar diferencias, sino en mejorar la comprensión contextual del fenómeno**. Para lograrlo, el investigador debe cumplir una secuencia rigurosa: justificar los grupos, evaluar invariancia, revisar calidad de medición, comparar rutas, interpretar diferencias con teoría y reconocer límites. Así, MICOM y MGA dejan de ser procedimientos técnicos aislados y se convierten en herramientas para construir explicaciones más precisas, menos universalistas y más sensibles a la diversidad empírica de las ciencias de la administración (Henseler et al., 2016).

Evaluación del poder predictivo del modelo

La evaluación del poder predictivo del modelo constituye una fase decisiva en PLS-SEM porque permite valorar si el modelo no solo explica relaciones dentro de la muestra analizada, sino si también puede anticipar adecuadamente resultados en casos no utilizados directamente para estimar el modelo. Esta distinción es central porque durante mucho tiempo muchos estudios asumieron que un modelo con relaciones significativas, valores aceptables de R^2 o buena coherencia teórica tenía automáticamente capacidad predictiva. Sin embargo, explicación y predicción no son equivalentes. Un modelo puede ser teóricamente sólido, presentar coeficientes estadísticamente significativos y explicar una proporción importante de varianza dentro de la muestra, pero aun así mostrar bajo desempeño al intentar predecir observaciones nuevas. Por ello, en la evaluación estructural no basta con

preguntar si los constructos se relacionan, si las hipótesis reciben apoyo o si la variable dependiente presenta un R^2 aceptable. También debe preguntarse si el modelo tiene utilidad predictiva. Hair et al. (2021) ubican la evaluación del poder predictivo como una sección específica dentro de la evaluación del modelo estructural, después de revisar colinealidad, significancia de relaciones y poder explicativo, lo que confirma que la predicción representa un criterio distinto dentro del proceso de análisis PLS-SEM. **La evaluación predictiva debe reconocer los límites de generalización del modelo y no asumir que una buena explicación interna equivale automáticamente a predicción robusta** (Shmueli, 2010).

Cuando se utiliza **PLSpredict**, el investigador debe interpretar los errores de predicción con cuidado. El **RMSE —Root Mean Squared Error—** penaliza con mayor fuerza los errores grandes, mientras que el **MAE —Mean Absolute Error—** calcula el promedio absoluto de errores sin elevarlos al cuadrado. Si el modelo PLS presenta valores menores de RMSE o MAE que el modelo de referencia, se obtiene evidencia favorable de capacidad predictiva. Si los errores son mayores, la capacidad predictiva puede ser limitada. No obstante, esta interpretación debe considerar el tipo de variable dependiente, la escala de medición y el propósito del estudio. **Los errores predictivos no son simples números técnicos; indican qué tan cerca está el modelo de anticipar valores observados en casos nuevos**. Su lectura fortalece la evaluación aplicada del modelo (Hair et al., 2021).

El punto de partida para comprender el poder predictivo es distinguir entre explicación, predicción y ajuste interno del modelo. La explicación busca comprender por qué ocurre un fenómeno y qué relaciones teóricas permiten interpretarlo; la predicción busca anticipar valores de una variable resultado con la mayor precisión posible; y el ajuste interno o explicación dentro de la muestra se refiere a qué tan bien los predictores explican la variación observada en los datos analizados. En PLS-SEM, esta diferencia es especialmente importante porque el método se presenta con frecuencia como causal-predictivo. Esto significa que no debe utilizarse únicamente para estimar coeficientes de trayectoria, sino también para valorar la capacidad del modelo de producir predicciones útiles. Shmueli (2010) advierte que en distintas disciplinas se confunden explicación y predicción, y que esa confusión puede debilitar la calidad de los modelos estadísticos. En términos prácticos, un investigador puede formular hipótesis correctamente y encontrar relaciones significativas, pero si el modelo no predice bien, su utilidad aplicada será limitada. Por ello, **la evaluación predictiva permite pasar de un modelo estadísticamente apoyado a un modelo potencialmente útil para anticipar resultados en contextos comparables**.

El R^2 es un punto de partida útil, pero no suficiente para afirmar que un modelo posee poder predictivo. El coeficiente de determinación indica la proporción de varianza explicada de un constructo endógeno por sus predictores. Por ejemplo, si un modelo obtiene un R^2 de .55 para intención de uso de inteligencia artificial, puede decirse que los constructos antecedentes explican el 55% de la variación observada en esa intención dentro de la muestra. Sin embargo, eso no significa necesariamente que el modelo pueda predecir adecuadamente la intención de uso en nuevos

estudiantes, profesores, usuarios u organizaciones. El R^2 evalúa principalmente desempeño dentro de la muestra; por eso puede aumentar cuando se agregan más predictores, incluso si algunos aportan poco sentido teórico o generan riesgo de sobreajuste. Guenther et al. (2023) señalan que el R^2 revela capacidades de predicción dentro de la muestra, pero también advierten que concentrarse demasiado en incrementarlo puede promover modelos sobreajustados, especialmente cuando se agregan constructos para elevar artificialmente la explicación de la variable dependiente. Por tanto, **un R^2 alto debe interpretarse como evidencia de poder explicativo interno, no como prueba definitiva de capacidad predictiva externa**.

La diferencia entre predicción dentro de la muestra y predicción fuera de la muestra es fundamental para evaluar correctamente un modelo PLS-SEM. La predicción dentro de la muestra se refiere a qué tan bien el modelo reproduce o explica los datos utilizados para estimarlo. En cambio, la predicción fuera de la muestra evalúa qué tan bien el modelo puede anticipar observaciones que no fueron utilizadas directamente en la estimación. Esta segunda forma es más exigente, porque obliga al modelo a mostrar utilidad más allá de los datos con los que fue construido. En investigación aplicada, esta diferencia tiene gran relevancia. Un modelo sobre adopción tecnológica puede explicar adecuadamente las respuestas de una muestra específica de estudiantes, pero fallar al predecir la intención de uso de otros estudiantes en otro grupo o cohorte. Un modelo sobre desempeño innovador puede funcionar bien en una muestra de empresas, pero no anticipar adecuadamente el desempeño de empresas no incluidas en la estimación. Por ello, **la capacidad predictiva no debe inferirse solo por el comportamiento interno del modelo, sino por su desempeño ante observaciones retenidas, nuevas o simuladas mediante procedimientos de validación**. Esta perspectiva es coherente con el llamado reciente a fortalecer la evaluación predictiva en PLS-SEM, especialmente cuando el investigador declara que su estudio tiene propósito práctico o causal-predictivo.

El criterio Q^2 de Stone-Geisser ha sido utilizado tradicionalmente para valorar la relevancia predictiva del modelo en PLS-SEM, pero debe interpretarse con cuidado. En términos generales, Q^2 permite evaluar si el modelo tiene capacidad para reconstruir valores observados de los constructos endógenos mediante procedimientos de omisión y predicción. Como regla orientativa, un valor de Q^2 mayor que cero suele interpretarse como evidencia de relevancia predictiva. Sin embargo, Q^2 no debe confundirse con una evaluación completa de predicción fuera de la muestra. Guenther et al. (2023) explican que el criterio Q^2, basado en blindfolding, fue sugerido tempranamente en la literatura PLS-SEM, pero también señalan que este procedimiento no representa plenamente una evaluación predictiva fuera de muestra, ya que no utiliza un conjunto de retención independiente en el sentido estricto. Por ello, Q^2 puede seguir siendo útil como diagnóstico de relevancia predictiva, pero no debe ser el único criterio cuando el estudio afirma que el modelo tiene capacidad predictiva real. **Q^2 indica si el modelo posee relevancia predictiva básica, pero la evaluación predictiva contemporánea exige procedimientos más robustos como PLSpredict**.

PLSpredict representa uno de los avances más importantes para evaluar el poder predictivo en PLS-SEM, porque permite valorar la capacidad del modelo para predecir observaciones no utilizadas directamente en la estimación. Este procedimiento utiliza validación cruzada, dividiendo la muestra en segmentos o pliegues. Una parte de los datos se usa para entrenar el modelo y otra parte se retiene para evaluar qué tan bien el modelo predice los valores observados. En una validación cruzada de diez pliegues, por ejemplo, nueve segmentos funcionan como muestra de entrenamiento y uno como muestra de retención; este proceso se repite hasta que cada observación haya sido predicha al menos una vez. Posteriormente, se calculan errores predictivos que permiten juzgar el desempeño del modelo. Guenther et al. (2023) explican que PLSpredict, desarrollado por Shmueli et al. (2016, 2019), permite una evaluación de predicción fuera de muestra y requiere comparar los errores de predicción del modelo PLS-SEM con puntos de referencia o alternativas ingenuas de predicción. Esto es relevante porque **un modelo no debe considerarse predictivo solo porque produzca valores estimados, sino porque sus errores de predicción sean menores o competitivos frente a modelos de referencia**.

La lógica de PLSpredict exige comprender que la predicción se evalúa mediante errores, no únicamente mediante significancia de relaciones. En un contraste tradicional de hipótesis, el investigador observa si una ruta es significativa, si el coeficiente tiene el signo esperado y si el intervalo de confianza no incluye cero. En predicción, en cambio, la pregunta cambia: ¿qué tan grande es el error cuando el modelo intenta anticipar valores de la variable resultado? Para responderla se utilizan métricas como RMSE y MAE. El RMSE, o raíz del error cuadrático medio, penaliza más fuertemente errores grandes, por lo que resulta sensible a predicciones muy alejadas del valor observado. El MAE, o error absoluto medio, mide el tamaño promedio de los errores en términos absolutos y suele ser más fácil de interpretar. Cuando estos errores son menores que los de un modelo de referencia, el modelo PLS-SEM muestra mejor desempeño predictivo. Si son iguales o mayores, la capacidad predictiva es débil o insuficiente. Por ello, **la predicción obliga a cambiar la mentalidad del investigador: no basta con saber si una relación existe; se debe evaluar qué tan bien el modelo anticipa valores empíricos concretos**. Esta diferencia evita confundir apoyo estadístico de hipótesis con utilidad predictiva real.

La evaluación predictiva debe relacionarse con el propósito del estudio. Si el objetivo del modelo es principalmente confirmatorio, puede ser suficiente concentrarse en la coherencia teórica, la significancia de las relaciones y los criterios de ajuste o explicación, según el enfoque SEM utilizado. Sin embargo, si el estudio declara que busca predecir intención de uso, desempeño, adopción, innovación, satisfacción, permanencia o cualquier resultado relevante para la toma de decisiones, entonces debe incluir una evaluación predictiva más explícita. Esta exigencia es especialmente importante en ciencias de la administración, porque muchos modelos pretenden orientar decisiones organizacionales, institucionales o educativas. Por ejemplo, si se afirma que la autoeficacia, la utilidad percibida y la confianza predicen la intención de uso de IA generativa, el lector tiene derecho a saber si el modelo realmente reduce errores de predicción en comparación con una alternativa simple. De igual manera, si

se afirma que capacidades digitales y aprendizaje organizacional predicen desempeño innovador, no basta con reportar rutas significativas; debe evaluarse si el modelo permite anticipar el desempeño de casos no observados. **La predicción tiene valor práctico porque convierte el modelo en una herramienta potencial para anticipar comportamientos o resultados, no solo para describir asociaciones dentro de una muestra**.

Un riesgo frecuente consiste en interpretar el poder predictivo como si fuera equivalente al apoyo empírico de las hipótesis. Una hipótesis puede recibir apoyo porque el coeficiente de trayectoria es positivo, significativo y consistente con la teoría, pero eso no garantiza que el modelo prediga bien. También puede ocurrir lo contrario: un modelo puede mostrar desempeño predictivo aceptable, pero ofrecer explicaciones teóricas limitadas. Esta diferencia no debe verse como contradicción, sino como evidencia de que explicación y predicción responden a criterios distintos. En un capítulo metodológico, esto debe enseñarse con claridad para evitar que el investigador use los resultados de manera imprecisa. La significancia estadística pertenece a la lógica de inferencia sobre relaciones; la predicción pertenece a la lógica de anticipación de valores. Por ello, el reporte debe separar ambas dimensiones: primero, qué relaciones se apoyan; segundo, qué capacidad explicativa tiene el modelo; tercero, qué capacidad predictiva presenta. **Un modelo SEM sólido no es solo aquel que confirma hipótesis, sino aquel que integra teoría, medición, explicación, predicción e interpretación sustantiva de manera coherente**. Esta integración es consistente con las recomendaciones recientes que piden reportes PLS-SEM más completos y menos mecánicos.

El poder predictivo también debe interpretarse en relación con la complejidad del modelo. Agregar más constructos puede aumentar el R^2, pero no necesariamente mejorar la predicción fuera de la muestra. De hecho, un modelo demasiado complejo puede ajustarse bien a los datos disponibles y funcionar mal con nuevos datos. Este fenómeno se conoce como sobreajuste. En PLS-SEM, el riesgo aparece cuando el investigador agrega variables, mediadores, moderadores o rutas adicionales con el objetivo de mejorar indicadores internos, sin una justificación conceptual sólida. La predicción fuera de muestra ayuda a detectar este problema, porque un modelo sobreajustado tiende a perder desempeño cuando se enfrenta a observaciones no utilizadas en la estimación. Por ello, **la evaluación predictiva protege contra modelos aparentemente fuertes pero poco generalizables**. En términos pedagógicos, el investigador debe aprender que un modelo más grande no siempre es más útil; un modelo predictivamente sólido puede ser más parsimonioso, teóricamente claro y empíricamente estable. Guenther et al. (2023) advierten que el incremento mecánico de R^2 por complejidad del modelo puede promover sobreajuste, por lo que la evaluación predictiva debe complementar la interpretación del poder explicativo.

La evaluación del poder predictivo debe presentarse como una etapa posterior a la evaluación del modelo de medición y del modelo estructural básico. Antes de preguntar si el modelo predice, el investigador debe asegurarse de que los constructos están correctamente especificados, que los indicadores son válidos, que

la confiabilidad es aceptable, que existe validez convergente y discriminante, que no hay colinealidad problemática y que las rutas estructurales tienen sentido teórico. Si el modelo de medición es débil, la predicción puede estar basada en constructos mal representados. Si el modelo estructural carece de lógica conceptual, una predicción aceptable puede resultar difícil de interpretar. Por ello, la predicción no sustituye las fases anteriores; las complementa. En el flujo de evaluación de Hair et al. (2021), la evaluación del poder predictivo aparece después de colinealidad, significancia de relaciones y poder explicativo, lo que muestra una secuencia lógica: primero se valida la estructura básica del modelo, luego se valora su capacidad explicativa y, posteriormente, se analiza su poder predictivo. **La predicción es una prueba adicional de utilidad empírica, no una licencia para ignorar teoría, medición o especificación del modelo**

La segunda fase de la evaluación predictiva consiste en interpretar los errores de predicción y no solo los coeficientes estructurales. En PLS-SEM, el investigador suele estar acostumbrado a revisar si las hipótesis fueron apoyadas mediante coeficientes de trayectoria, valores *t*, valores *p* e intervalos de confianza; sin embargo, la lógica predictiva exige otro tipo de lectura. La pregunta ya no es únicamente si una relación es significativa, sino **qué tan lejos quedan las predicciones del modelo respecto a los valores observados**. Por ello, métricas como **RMSE** y **MAE** adquieren relevancia. El **RMSE** —*Root Mean Square Error*— calcula la raíz del promedio de los errores cuadrados; al elevar los errores al cuadrado, penaliza con mayor fuerza las predicciones muy alejadas del valor real. El **MAE** —*Mean Absolute Error*— calcula el promedio de los errores absolutos y ofrece una lectura más directa del error promedio. En términos prácticos, si un modelo predice la intención de uso de IA generativa, el RMSE y el MAE permiten valorar qué tan grande es la distancia entre la intención observada y la intención predicha. **Mientras menor sea el error, mejor será el desempeño predictivo**, siempre que se compare contra un punto de referencia adecuado. Shmueli et al. (2019) plantean precisamente que la evaluación predictiva en PLS-SEM debe apoyarse en procedimientos como PLSpredict y en métricas de error que permitan valorar el desempeño predictivo del modelo, no solo su significancia estructural.

La comparación con modelos de referencia es indispensable porque un error bajo no siempre significa buen poder predictivo. Un modelo PLS-SEM puede generar predicciones, pero esas predicciones solo son útiles si superan o igualan razonablemente el desempeño de una alternativa más simple. Por ello, PLSpredict suele comparar los errores del modelo PLS-SEM con los errores de un modelo lineal de referencia, conocido comúnmente como **LM**. Esta comparación permite responder una pregunta más rigurosa: **¿el modelo teórico construido por el investigador predice mejor que una alternativa estadística más simple?** Si el modelo PLS-SEM produce errores menores que el modelo de referencia para la mayoría de los indicadores del constructo endógeno, puede hablarse de poder predictivo favorable. Si los errores son similares, el poder predictivo puede considerarse moderado o limitado. Si los errores del modelo PLS-SEM son mayores que los del modelo de referencia, la capacidad predictiva debe ponerse en duda, aunque el modelo tenga rutas

significativas o R^2 aceptable. Esta lógica es muy importante porque evita confundir complejidad con utilidad. Un modelo con muchos constructos, mediadores y moderadores puede verse sofisticado, pero si no predice mejor que una alternativa simple, su valor aplicado es limitado. Guenther et al. (2023) advierten que los estudios PLS-SEM suelen justificar el uso del método por predicción, aunque con frecuencia no aplican de manera suficiente procedimientos predictivos avanzados.

La interpretación de Q^2 _predict debe distinguirse del Q^2 tradicional de Stone-Geisser. El Q^2 tradicional se ha utilizado para valorar relevancia predictiva mediante procedimientos de omisión y reconstrucción, generalmente asociados con *blindfolding*. Como orientación básica, $\boldsymbol{Q^2 > 0}$ indica que el modelo posee cierta relevancia predictiva para un constructo endógeno. Sin embargo, la evaluación contemporánea mediante PLSpredict incorpora una lógica más exigente, porque se apoya en validación cruzada y comparación de errores predictivos. En este contexto, **Q^2 _predict** ayuda a valorar si las predicciones del modelo son mejores que una predicción ingenua basada en promedios. Si Q^2 _predict es positivo, puede interpretarse que el modelo supera ese punto de referencia básico; si es cero o negativo, la capacidad predictiva es insuficiente frente a una predicción muy simple. No obstante, Q^2 _predict tampoco debe interpretarse de manera aislada. Lo recomendable es leerlo junto con **RMSE, MAE y la comparación frente al modelo lineal de referencia**. En otras palabras, el investigador no debe declarar poder predictivo únicamente porque un índice es positivo; debe observar el patrón completo de resultados. Hair et al. (2021) destacan que los desarrollos recientes en PLS-SEM incorporan la evaluación del poder predictivo mediante PLSpredict como parte de los avances contemporáneos en la evaluación de modelos.

El **análisis importancia-rendimiento** permite ampliar la utilidad aplicada de PLS-SEM porque combina dos preguntas distintas: **qué tan importante es un constructo para explicar o mejorar una variable objetivo** y **qué nivel de rendimiento presenta ese constructo en la muestra analizada**. Esta combinación es útil porque un antecedente puede tener alta importancia, pero bajo rendimiento; en ese caso, representa una prioridad de intervención. En cambio, un antecedente con alto rendimiento y baja importancia puede no requerir atención inmediata. Por ejemplo, si el desempeño innovador es la variable objetivo, IPMA puede mostrar que la capacidad digital tiene alta importancia y bajo rendimiento, lo que justificaría priorizar acciones de fortalecimiento tecnológico. Esta lectura es especialmente valiosa en investigaciones aplicadas, porque permite transformar los resultados del modelo en decisiones gerenciales: no basta con saber qué relación es significativa, también importa identificar **dónde existe mayor oportunidad de mejora**. Por ello, IPMA funciona como un puente entre la evaluación predictiva y la formulación de recomendaciones estratégicas basadas en evidencia (Ringle & Sarstedt, 2016).

El poder predictivo puede clasificarse de manera orientativa en bajo, medio o alto, pero siempre con prudencia y considerando el contexto del estudio. Una lectura útil consiste en observar cuántos indicadores del constructo endógeno presentan errores menores en PLS-SEM frente al modelo de referencia. Si la mayoría

de los indicadores tienen menor RMSE o MAE en el modelo PLS-SEM, puede hablarse de poder predictivo alto. Si solo algunos indicadores presentan mejor desempeño y otros son similares, el poder predictivo puede considerarse medio. Si la mayoría de los errores son mayores que los del modelo de referencia, el poder predictivo es bajo o no satisfactorio. Sin embargo, estos niveles no deben aplicarse de manera mecánica. En fenómenos sociales complejos —como desempeño innovador, aprendizaje organizacional, intención de adopción tecnológica o sostenibilidad— es posible que la predicción sea más difícil que en fenómenos altamente estables o repetitivos. Por ello, **la interpretación debe combinar criterios estadísticos, naturaleza del fenómeno, calidad de medición, tamaño de muestra y propósito del estudio**. Un modelo con poder predictivo moderado puede ser valioso si el fenómeno es complejo y los predictores son teóricamente relevantes. Por el contrario, un modelo con poder predictivo alto, pero pobre fundamento teórico, puede ser útil para anticipar valores, aunque no necesariamente para explicar el fenómeno. Shmueli (2010) advierte que explicación y predicción deben tratarse como metas distintas del modelado estadístico.

Uno de los errores más frecuentes es afirmar que el modelo "predice" solo porque tiene un R^2 elevado. El R^2 informa cuánta varianza del constructo endógeno es explicada por sus predictores dentro de la muestra analizada, pero no necesariamente indica que el modelo funcione bien con observaciones no usadas para la estimación. De hecho, un R^2 alto puede surgir por la inclusión de numerosos predictores, por redundancia conceptual entre constructos o por sobreajuste. El sobreajuste ocurre cuando el modelo se ajusta demasiado bien a la muestra disponible, pero pierde desempeño al intentar generalizar a otros casos. En investigación aplicada, esto es especialmente delicado porque puede generar una falsa sensación de utilidad. Por ejemplo, un modelo puede explicar el 70% de la intención de uso en una muestra de estudiantes, pero no predecir adecuadamente la intención de uso en otra universidad, cohorte o contexto. Por ello, **R^2 debe interpretarse como poder explicativo interno, no como prueba suficiente de poder predictivo externo**. La evaluación predictiva mediante PLSpredict ayuda a corregir esta limitación porque obliga a revisar errores de predicción fuera de la muestra de entrenamiento. Guenther et al. (2023) señalan que una concentración excesiva en R^2 puede favorecer modelos sobreajustados y que la evaluación predictiva debe complementar la interpretación del modelo PLS-SEM.

Otro error común consiste en reportar PLSpredict sin interpretar sus resultados de manera sustantiva. Algunos estudios incluyen una tabla con RMSE, MAE o Q^2 _predict, pero no explican qué significan esos valores para el fenómeno analizado. El reporte debe ir más allá de presentar números. Debe explicar si el modelo predice adecuadamente la variable dependiente, si supera al modelo de referencia, qué indicadores presentan mejor o peor desempeño y qué implicaciones tiene esto para la teoría o la práctica. Por ejemplo, si un modelo predice bien la intención de adopción tecnológica, puede sugerirse que los constructos incluidos —como autoeficacia, utilidad percibida o confianza— son útiles para anticipar la disposición de los usuarios. Si el modelo predice mal, el investigador debe reconocer que, aunque algunas hipótesis hayan sido apoyadas, el modelo tiene limitada utilidad predictiva. **Un**

buen reporte no oculta resultados débiles; los interpreta como evidencia para mejorar teoría, medición o especificación futura. También debe evitar expresiones absolutas como "el modelo tiene excelente predicción" si solo algunos indicadores muestran desempeño favorable. La interpretación debe ser proporcional a los resultados. Hair et al. (2019) recomiendan reportar PLS-SEM con criterios adecuados y evitar reportes incompletos o mecánicos, especialmente cuando se afirma una orientación predictiva.

La evaluación predictiva también puede orientar decisiones sobre la parsimonia del modelo. Un modelo parsimonioso incluye los constructos necesarios para explicar o predecir el fenómeno, sin agregar variables innecesarias. PLSpredict puede mostrar que un modelo más simple predice igual o mejor que uno más complejo. Esto es relevante porque, en PLS-SEM, la posibilidad de estimar modelos complejos puede llevar al investigador a incluir muchas relaciones, constructos y efectos indirectos. Sin embargo, **la complejidad solo se justifica si mejora la comprensión o la predicción del fenómeno**. Si un modelo con cinco predictores no predice mejor que uno con tres, conviene revisar si los predictores adicionales aportan valor real. Esta reflexión es muy útil en estudios de administración e innovación, donde abundan modelos con múltiples capacidades, orientaciones, recursos y contextos. La evaluación predictiva permite identificar si cada constructo contribuye a anticipar el resultado o si solo aumenta complejidad estadística. Esta lectura no sustituye la teoría, pero ayuda a mejorarla. Un modelo predictivamente débil puede indicar que faltan variables relevantes, que sobran constructos redundantes o que el fenómeno requiere una especificación distinta. Dijkstra y Henseler (2015) muestran que la discusión sobre técnicas SEM debe considerar la naturaleza de los modelos y sus implicaciones para la estimación, lo cual refuerza la necesidad de elegir modelos parsimoniosos y coherentes.

En términos de redacción académica, el reporte del poder predictivo debe integrarse después de la evaluación del modelo estructural. Una secuencia recomendable sería: primero, informar que el modelo de medición cumplió criterios mínimos de confiabilidad y validez; segundo, presentar la evaluación estructural mediante colinealidad, coeficientes de trayectoria, significancia, R^2 y f^2 ; tercero, reportar Q^2 o relevancia predictiva; cuarto, presentar PLSpredict con RMSE, MAE, Q^2 _predict y comparación con el modelo de referencia; finalmente, interpretar el grado de poder predictivo. Una redacción posible sería: **"Los resultados de PLSpredict muestran que el modelo presenta poder predictivo moderado, ya que la mayoría de los indicadores del constructo endógeno obtuvieron valores de RMSE y MAE inferiores o similares al modelo lineal de referencia. Además, los valores positivos de Q^2 _predict sugieren que el modelo supera una predicción ingenua basada en promedios. No obstante, algunos indicadores presentaron errores superiores, por lo que la capacidad predictiva debe interpretarse con cautela y como evidencia parcial de utilidad predictiva."** Esta forma de reporte es equilibrada porque no exagera los hallazgos y vincula la predicción con los datos observados. Shmueli et al. (2019) proponen directrices para usar PLSpredict precisamente con el propósito de mejorar la evaluación predictiva en PLS-SEM.

La evaluación del poder predictivo tiene implicaciones importantes para tesis, artículos y reportes aplicados. En una tesis, permite demostrar que el estudiante no se limitó a contrastar hipótesis, sino que comprendió la utilidad empírica del modelo. En un artículo científico, fortalece el reporte porque responde a las exigencias actuales de PLS-SEM, donde se espera mayor rigor en la justificación del método y en la evaluación predictiva. En un reporte aplicado, resulta aún más relevante porque permite traducir el modelo en criterios para anticipar resultados organizacionales, educativos o de mercado. Por ejemplo, una institución educativa puede usar un modelo predictivo para anticipar intención de uso de plataformas digitales; una empresa puede anticipar desempeño innovador; una organización pública puede identificar factores que predicen adopción de servicios digitales. No obstante, **la predicción no debe convertirse en promesa determinista**. Un modelo predictivo ofrece estimaciones probabilísticas o aproximadas, no certezas absolutas. Por ello, el reporte debe reconocer límites: tamaño y tipo de muestra, contexto, estabilidad del fenómeno, calidad de indicadores, diseño transversal o longitudinal y posibilidad de generalización. Guenther et al. (2023) enfatizan la necesidad de mejorar las prácticas de uso, justificación, evaluación y reporte de PLS-SEM, especialmente en investigación aplicada.

En conclusión, evaluar el poder predictivo del modelo significa valorar si la arquitectura SEM tiene utilidad más allá de explicar relaciones dentro de la muestra. El investigador debe distinguir entre significancia, explicación y predicción.

La significancia indica si una relación estimada difiere estadísticamente de cero; el R^2 indica cuánta varianza se explica dentro del modelo; el Q^2 ofrece evidencia básica de relevancia predictiva; y PLSpredict permite examinar desempeño predictivo mediante validación cruzada, errores de predicción y comparación con modelos de referencia. En este sentido, **un modelo PLS-SEM maduro no debe reportar únicamente hipótesis apoyadas, sino también su capacidad para anticipar resultados de manera empíricamente útil**. Esta evaluación mejora la calidad metodológica del estudio, evita afirmaciones exageradas y permite diferenciar modelos explicativos de modelos predictivos. Para el lector del libro, la idea central es clara: **predecir no es lo mismo que explicar, y demostrar poder predictivo exige evidencia específica**. Cuando se reporta con rigor, la evaluación predictiva convierte al modelo en una herramienta más completa para la investigación y la práctica, especialmente en campos donde interesa anticipar adopción, desempeño, innovación, aprendizaje, satisfacción o sostenibilidad. Hair et al. (2021) sitúan la evaluación del poder predictivo como parte del proceso contemporáneo de evaluación del modelo estructural en PLS-SEM, lo cual confirma su relevancia metodológica.

Comparación de modelos

La comparación de modelos constituye una fase avanzada de la evaluación SEM porque permite valorar si la estructura propuesta por el investigador es realmente la alternativa más coherente, parsimoniosa y útil frente a otras configuraciones posibles. En un estudio de ecuaciones estructurales no basta con

demostrar que un modelo tiene coeficientes significativos, valores aceptables de R^2, indicadores de ajuste razonables o capacidad predictiva preliminar. También es necesario preguntarse si esa arquitectura relacional representa mejor el fenómeno que otras alternativas conceptualmente defendibles. Un modelo puede funcionar estadísticamente y, aun así, no ser el más adecuado si existe una configuración más simple, más clara o con mejor desempeño predictivo. Por ejemplo, un modelo puede proponer una relación directa entre capacidades digitales y desempeño innovador; otro puede plantear que esa relación ocurre mediante aprendizaje organizacional; y otro puede sostener que el efecto depende de la turbulencia ambiental. Las tres posibilidades pueden ser teóricamente razonables, pero no necesariamente tienen el mismo valor explicativo o predictivo. Por ello, **comparar modelos no significa probar opciones al azar hasta obtener mejores resultados, sino contrastar configuraciones derivadas de teorías, mecanismos o supuestos distintos**. La comparación ayuda a justificar por qué se conserva una estructura y no otra, evitando que el investigador presente su modelo como si fuera la única representación posible del fenómeno. **En este sentido, el mejor modelo no es siempre el más complejo ni el que incluye más flechas, sino el que logra integrar teoría, medición, parsimonia, explicación y predicción con mayor equilibrio metodológico.** (Hair et al., 2021).

La comparación de modelos también puede enriquecerse al distinguir entre relaciones de suficiencia y condiciones necesarias. En PLS-SEM, una relación estructural suele interpretarse como evidencia de que un antecedente contribuye a explicar o predecir una variable dependiente; sin embargo, en algunos fenómenos administrativos puede ser igualmente importante preguntar si existe un nivel mínimo de cierto antecedente sin el cual el resultado alto no puede alcanzarse. Esta lógica cambia la lectura del modelo: un constructo puede no ser el predictor más fuerte en términos de coeficiente *path* y, aun así, funcionar como una condición indispensable. Por ejemplo, una empresa puede requerir un nivel mínimo de capacidad digital para alcanzar alto desempeño innovador, aunque otros constructos expliquen mejor la variación total del desempeño. Por ello, NCA permite distinguir entre variables que **ayudan a mejorar el resultado** y variables que **deben estar presentes** para que el resultado sea posible. Esta distinción fortalece la comparación de modelos porque permite valorar no solo cuál especificación explica o predice más, sino cuál identifica mejor los umbrales necesarios para alcanzar niveles altos de la variable objetivo (Richter et al., 2020).

Una extensión aplicada de esta lógica consiste en integrar importancia, rendimiento y necesidad mediante el enfoque cIPMA. Esta combinación permite diferenciar entre variables que influyen en el resultado, variables que presentan bajo desempeño y variables que representan condiciones mínimas para alcanzar niveles altos de la variable objetivo. En términos prácticos, una variable puede ser importante para el modelo, mostrar bajo rendimiento y además funcionar como condición necesaria; en ese caso, su prioridad estratégica es mayor que la de una variable que solo resulta significativa. Por el contrario, un constructo puede tener buen rendimiento y no ser necesario, lo que reduce su urgencia como foco de intervención. Esta lectura

permite que la comparación de modelos no se limite a elegir la especificación con mejores índices, sino que ayude a identificar qué antecedentes deben mantenerse, cuáles deben mejorarse y cuáles representan **umbrales mínimos** para lograr el resultado esperado. Así, cIPMA fortalece la utilidad aplicada del modelo porque combina la lógica gerencial del IPMA con la lógica de necesidad del NCA (Sarstedt et al., 2024).

La evaluación global también debe cuidar la interpretación de hipótesis no apoyadas. Una hipótesis no significativa no siempre significa que la teoría sea falsa. Puede deberse a baja potencia estadística, problemas de medición, falta de variabilidad en los datos, muestra heterogénea, colinealidad o condiciones contextuales no consideradas. Por ejemplo, una relación entre liderazgo e innovación puede no ser significativa si las empresas estudiadas tienen baja autonomía, alta regulación o poca capacidad de implementar cambios. En este caso, el contexto puede explicar por qué una relación teóricamente esperada no aparece en los datos. El investigador debe evitar conclusiones absolutas como “no existe relación” y preferir formulaciones prudentes: “la relación no fue apoyada en esta muestra” o “no se obtuvo evidencia suficiente para sostener la hipótesis”. **La ausencia de significancia debe discutirse como resultado metodológico y contextual, no como negación definitiva del fenómeno** (Hair et al., 2021).

La evaluación del modelo estructural también debe considerar el orden lógico de interpretación. Primero se verifica colinealidad entre predictores; después se analizan coeficientes *path* y significancia; luego se interpreta R^2 ; posteriormente se revisa f^2 ; y, finalmente, se evalúa Q^2 o PLSpredict si el propósito incluye predicción. Este orden evita interpretar efectos antes de confirmar condiciones básicas. Por ejemplo, no conviene discutir ampliamente un coeficiente *path* si los predictores presentan colinealidad severa, porque el efecto individual puede estar distorsionado. Tampoco conviene celebrar un R^2 alto si fue obtenido mediante constructos redundantes. **La evaluación estructural debe seguir una secuencia lógica para evitar conclusiones prematuras**. Esta secuencia ayuda al estudiante a comprender que SEM no es una colección de tablas, sino un proceso progresivo de validación, interpretación y argumentación (Hair et al., 2021).

El análisis estructural debe incorporar una lectura sobre la capacidad explicativa relativa de los constructos endógenos. No todos los constructos dependientes del modelo tendrán el mismo nivel de R^2 . Algunos pueden estar bien explicados por sus antecedentes, mientras otros pueden mostrar menor varianza explicada. Por ejemplo, un modelo puede explicar adecuadamente la **intención de uso**, pero explicar menos la **conducta real de uso**, porque esta última depende de restricciones externas, recursos o hábitos no incluidos en el modelo. Esta diferencia no invalida el estudio; permite identificar qué partes del modelo están mejor desarrolladas y cuáles requieren ampliación futura. **El R^2 debe interpretarse por cada constructo endógeno, no como una propiedad única de todo el modelo**. Esta lectura ayuda a distinguir entre zonas fuertes y zonas débiles del sistema estructural (Hair et al., 2019).

El f^2 también debe interpretarse de manera relacional. Su utilidad consiste en mostrar qué predictores aportan más a la explicación de cada constructo endógeno. Por ejemplo, en un modelo de desempeño innovador, la capacidad digital puede tener un efecto pequeño, el aprendizaje organizacional uno mediano y la cultura innovadora uno grande. Esta información permite ordenar la importancia relativa de los antecedentes. Sin embargo, no debe confundirse importancia estadística con prioridad práctica automática. Un predictor con f^2 pequeño puede ser relevante si es más fácil de intervenir o si representa una variable estratégica emergente. Por ello, **el tamaño del efecto debe interpretarse junto con el contexto de aplicación y la teoría del fenómeno**. Esta lectura evita que el investigador descarte variables solo porque su aporte cuantitativo es menor (Cohen, 1992).

En estudios aplicados a administración, innovación o sostenibilidad, la evaluación estructural debe traducirse en **implicaciones teóricas y prácticas**. Si una relación es significativa y tiene un tamaño de efecto relevante, puede sugerir una ruta prioritaria de intervención. Por ejemplo, si el aprendizaje organizacional muestra un efecto importante sobre desempeño innovador, las organizaciones podrían fortalecer mecanismos de intercambio de conocimiento. Si la capacidad digital tiene relevancia predictiva, puede justificar estrategias de inversión tecnológica. Sin embargo, las implicaciones deben formularse con prudencia. Un modelo SEM basado en datos transversales no debe convertirse en receta causal absoluta. **Las implicaciones deben derivarse de la evidencia obtenida, pero respetando los límites del diseño metodológico** (Hair et al., 2021).

La capacidad predictiva del modelo también debe analizarse considerando la diferencia entre **predicción interna** y **predicción externa**. R^2 y Q^2 ofrecen información útil sobre la explicación y relevancia predictiva dentro del marco del modelo; PLSpredict permite avanzar hacia una evaluación más cercana a la predicción fuera de muestra. Esta distinción es crucial porque un modelo puede mostrar buen desempeño explicativo dentro de los datos usados, pero no anticipar adecuadamente nuevos casos. En ciencias administrativas, donde los contextos cambian con rapidez, la predicción externa adquiere relevancia. Por ejemplo, un modelo de adopción tecnológica puede explicar bien una muestra de estudiantes, pero no necesariamente predecir igual en docentes, directivos o empresas.

La evaluación global también debe considerar la **robustez del modelo ante resultados mixtos**. Es frecuente que algunas hipótesis sean apoyadas y otras no; que un constructo tenga R^2 alto y otro bajo; que Q^2 sea positivo para ciertos resultados, pero no para todos; o que PLSpredict muestre desempeño favorable solo en algunas variables. Esto no significa necesariamente que el modelo sea deficiente. Los fenómenos administrativos son complejos y rara vez se comportan de manera perfectamente uniforme. Lo importante es interpretar los resultados con equilibrio: identificar relaciones fuertes, relaciones débiles, zonas predictivas y limitaciones. **Un buen reporte SEM no oculta resultados mixtos; los organiza y los explica con criterio metodológico**. Esta práctica **puede fortalecer** la credibilidad académica y ayuda a evitar una lectura artificialmente optimista del modelo (Hair et al., 2021).

La evaluación estructural debe evitar el sobreajuste interpretativo. Esto ocurre cuando el investigador fuerza explicaciones para justificar cualquier resultado, incluso cuando la evidencia es débil. Por ejemplo, si una relación no significativa se interpreta como hallazgo teórico fuerte sin respaldo suficiente, se cae en sobreinferencia. La interpretación debe estar proporcionalmente ajustada a la evidencia. Una relación fuerte, significativa y con f^2 relevante permite afirmaciones más sólidas; una relación débil o no significativa requiere lenguaje cauteloso. La calidad académica del análisis depende de no exagerar **lo que el modelo permite sostener con la evidencia disponible**.En SEM, los resultados deben discutirse con precisión: qué se apoya, qué no se apoya, qué se explica parcialmente y qué queda abierto para futuras investigaciones (Gefen et al., 2000).

La evaluación global del modelo estructural también debe considerar la comparación entre modelos alternativos, cuando sea pertinente. En algunos estudios, el investigador puede comparar un modelo teórico principal con una versión alternativa más parsimoniosa o con rutas adicionales justificadas. Esto permite revisar si el modelo propuesto ofrece **una explicación más parsimoniosa, coherente o mejor sustentada** que otras configuraciones posibles. Sin embargo, la comparación no debe convertirse en búsqueda oportunista de mejores resultados. Debe estar guiada por teoría. **Los modelos alternativos son útiles cuando permiten contrastar explicaciones plausibles, no cuando se utilizan para ajustar resultados sin fundamento conceptual**. Esta práctica puede fortalecer la defensa del modelo final (Hair et al., 2021).

Un elemento importante es la **coherencia entre evaluación estructural y discusión de resultados**. La discusión no debe limitarse a repetir tablas. Debe explicar qué significan los coeficientes, qué hipótesis se apoyan, qué relaciones aportan más, qué constructos fueron mejor explicados y qué capacidad predictiva mostró el modelo. También debe conectar los hallazgos con el problema de investigación. Por ejemplo, si el objetivo era explicar desempeño innovador, la discusión debe señalar cuáles antecedentes resultaron más relevantes y qué implicaciones tiene para la teoría y la práctica. **La evaluación estructural solo adquiere valor académico cuando se traduce en una interpretación sustantiva del fenómeno estudiado** (Hair et al., 2021).

La evaluación global también debe reconocer las limitaciones del modelo. Un modelo PLS-SEM puede mostrar resultados sólidos y aun así tener limitaciones por diseño transversal, muestra no probabilística, uso de autoinformes, contexto específico o ausencia de variables relevantes. Reconocer estas limitaciones no debilita el estudio; lo vuelve más creíble. Por ejemplo, si todos los datos provienen del mismo informante, debe mencionarse el posible sesgo de método común. Si la muestra pertenece a un sector específico, debe limitarse la generalización. Si el modelo explica una proporción moderada de varianza, puede señalarse que existen otros factores no incluidos. **La interpretación responsable incluye tanto fortalezas como límites del modelo** (Gefen et al., 2000).

La evaluación global del modelo estructural debe cerrar integrando **explicación, predicción y coherencia teórica**. Un modelo PLS-SEM robusto no es aquel que reporta muchos índices, sino aquel que articula resultados consistentes con su propósito investigativo. Los coeficientes *path* muestran la dirección y fuerza de las relaciones; el *bootstrapping* aporta evidencia de significancia; R^2 expresa capacidad explicativa; f^2 indica el aporte individual de predictores; Q^2 y PLSpredict permiten valorar relevancia predictiva. Sin embargo, todos estos criterios deben interpretarse dentro del marco conceptual construido previamente. **La evaluación estructural es el punto donde teoría, medición y datos se encuentran para responder si el modelo realmente explica o predice el fenómeno estudiado** (Hair et al., 2021).

La comparación de modelos parte del reconocimiento de que los fenómenos administrativos, educativos, organizacionales y tecnológicos rara vez admiten una sola representación estructural. En ciencias de la administración, un mismo resultado puede ser explicado desde perspectivas distintas. La adopción de una tecnología puede analizarse desde la utilidad percibida, la facilidad de uso, la confianza, el riesgo, la autoeficacia o la influencia social. El desempeño innovador puede explicarse desde capacidades digitales, aprendizaje organizacional, liderazgo, cultura innovadora, orientación al mercado o recursos estratégicos. La satisfacción del usuario puede relacionarse con calidad percibida, valor, confianza, experiencia previa o expectativas. Por ello, la comparación de modelos permite evaluar cuál de esas explicaciones ofrece una estructura más convincente frente a otras posibilidades. No se trata de negar la validez de las explicaciones alternativas, sino de identificar cuál resulta más pertinente para la muestra, el contexto, la teoría y el propósito del estudio. Esta práctica fortalece la defensa científica del modelo porque obliga al investigador a demostrar que su propuesta no solo es posible, sino también preferible frente a otras configuraciones razonables. **Un modelo gana fuerza cuando se muestra que su estructura supera a una alternativa directa, más simple, más compleja o teóricamente rival**, siempre que la comparación sea transparente y conceptualmente justificada. Así, la comparación de modelos se convierte en un ejercicio de razonamiento científico y no únicamente en una actividad estadística posterior a la estimación. (Reinartz et al., 2009).

En PLS-SEM, la comparación de modelos tiene una relevancia especial porque este enfoque suele utilizarse con orientación causal-predictiva y con interés en explicar constructos endógenos. Si el investigador afirma que su modelo explica o predice un resultado, como intención de uso, desempeño innovador, satisfacción, adopción tecnológica, aprendizaje organizacional o sostenibilidad, entonces resulta pertinente preguntarse si otra configuración podría lograr un mejor desempeño con menor complejidad. Un modelo con más constructos puede aumentar el R^2 , pero eso no significa automáticamente que sea superior. Puede ocurrir que el incremento del R^2 sea mínimo, que las variables adicionales sean redundantes, que exista colinealidad o que la interpretación se vuelva innecesariamente confusa. También puede suceder que un modelo más simple logre un desempeño predictivo similar, pero con mayor claridad conceptual. En esos casos, el modelo parsimonioso puede ser preferible. Esta reflexión es crucial porque PLS-SEM permite estimar modelos complejos con relativa

facilidad, lo que puede llevar a incluir más variables, rutas, mediadores o moderadores de los que realmente requiere la pregunta de investigación. **La comparación de modelos protege contra la idea equivocada de que más complejidad equivale a más rigor**. Un modelo robusto no es el que contiene más relaciones, sino el que representa el fenómeno con la complejidad necesaria y suficiente. Por tanto, la comparación permite identificar si una estructura amplia realmente aporta valor o si solo produce un modelo más pesado, difícil de interpretar y menos replicable. (Guenther et al., 2023).

Una primera finalidad de la comparación de modelos es contrastar teorías o explicaciones alternativas sobre un mismo fenómeno. En investigación estructural, una teoría puede sostener que una variable antecedente influye directamente en una variable dependiente, mientras otra perspectiva puede afirmar que esa influencia ocurre mediante mecanismos intermedios o condiciones contextuales. Por ejemplo, en adopción tecnológica, un modelo basado en aceptación tecnológica puede enfatizar utilidad percibida y facilidad de uso; un modelo basado en confianza puede añadir seguridad, riesgo y credibilidad; y un modelo basado en aprendizaje puede incorporar autoeficacia, alfabetización digital o experiencia previa. La comparación permite observar cuál de esas estructuras tiene mayor capacidad para explicar o predecir el resultado central. Sin embargo, el objetivo no es declarar que una teoría es universalmente verdadera y otra falsa, sino identificar cuál configuración funciona mejor dentro de una muestra, contexto y operacionalización específicos. **La comparación de modelos permite transformar explicaciones rivales en evidencia evaluable**, porque no se limita a afirmar que una relación es plausible, sino que pregunta si una arquitectura conceptual es más fuerte que otra para representar el fenómeno. Esta lógica es especialmente valiosa cuando la literatura presenta hallazgos dispersos, contradicciones empíricas o modelos parcialmente solapados. En esos casos, comparar modelos ayuda a organizar el debate y a ofrecer una contribución más sólida. (Shmueli, 2010).

Una segunda finalidad consiste en evaluar configuraciones estructurales distintas dentro de una misma teoría general. Un investigador puede aceptar que X se relaciona con Y, pero dudar si esa relación debe modelarse como directa, mediada, moderada o mediada-moderada. Por ejemplo, si se estudia la relación entre capacidades digitales y desempeño innovador, un modelo directo supone que las capacidades digitales influyen en el desempeño sin necesidad de explicar el proceso intermedio. Un modelo mediado sostiene que esa relación ocurre a través del aprendizaje organizacional, la agilidad o la absorción de conocimiento. Un modelo moderado plantea que la relación cambia según el nivel de turbulencia ambiental, cultura innovadora o apoyo directivo. Cada configuración representa una lógica distinta. El modelo directo prioriza la relación principal; el modelo mediado explica el mecanismo; el modelo moderado introduce condiciones. Compararlos permite decidir si el fenómeno se representa mejor como una relación simple, como un proceso o como una relación dependiente del contexto. **La mediación y la moderación no deben incorporarse por ornamentación estadística, sino porque mejoran la comprensión del fenómeno**. Si el mediador no aporta una explicación clara o si el

moderador no cambia de manera relevante la relación, la complejidad añadida puede ser innecesaria. Por ello, la comparación de modelos ayuda a conservar solo aquellas estructuras que fortalecen la teoría y la interpretación. (Nitzl et al., 2016).

Una tercera finalidad de la comparación de modelos es seleccionar la estructura con mejor equilibrio entre parsimonia y desempeño empírico. La parsimonia no significa construir modelos pobres o excesivamente simples; significa incluir solo los constructos, rutas y efectos necesarios para responder la pregunta de investigación. En SEM, cada variable adicional exige definición conceptual, indicadores, justificación teórica, evaluación de validez y análisis de su función dentro del sistema. Por ello, agregar constructos sin necesidad puede debilitar el modelo, aunque algunos indicadores estadísticos parezcan mejorar. Un modelo parsimonioso es aquel que explica o predice suficientemente sin incorporar relaciones redundantes. Por ejemplo, si un modelo con tres predictores ofrece prácticamente el mismo desempeño que uno con seis, y los tres predictores adicionales no aportan una contribución teórica clara, el modelo más breve puede ser preferible. Esto es especialmente importante en investigaciones aplicadas, donde la utilidad del modelo también depende de su capacidad para ser comprendido, comunicado y replicado. **El mejor modelo no es necesariamente el que maximiza todos los indicadores, sino el que ofrece una representación clara, estable y defendible del fenómeno**. La comparación de modelos permite hacer visible este equilibrio entre complejidad y utilidad. (Hair et al., 2021).

En PLS-SEM, uno de los criterios utilizados para comparar modelos es el BIC, o *Bayesian Information Criterion*, porque permite valorar simultáneamente desempeño y complejidad. La lógica general del BIC es penalizar los modelos que agregan demasiados parámetros sin aportar una mejora suficiente. Esto significa que un modelo no se prefiere únicamente porque explica un poco más de varianza, sino porque logra un mejor balance entre explicación, predicción y parsimonia. En términos prácticos, cuando se comparan dos o más modelos alternativos, el modelo con menor BIC suele considerarse preferible para el constructo objetivo evaluado. No obstante, esta regla debe interpretarse con prudencia. Un BIC menor no significa que el modelo sea verdadero en términos absolutos; significa que, entre las alternativas comparadas, esa configuración ofrece mejor balance relativo. Por ejemplo, si un modelo mediado presenta menor BIC que un modelo directo, puede interpretarse que la mediación ofrece una estructura más adecuada dentro del conjunto evaluado, siempre que el mecanismo sea teóricamente defendible. **El BIC no sustituye la teoría, pero ayuda a evitar que el investigador elija automáticamente el modelo más complejo solo porque genera un indicador interno más favorable**. Por ello, su función es apoyar la decisión metodológica, no reemplazar el juicio conceptual. (Hair et al., 2021).

La comparación mediante BIC, GM (*Geweke-Meese Criterion*), AIC *(Akaike information Criterion*) u otros criterios solo tiene sentido cuando los modelos son conceptualmente comparables y compiten por explicar o predecir el mismo resultado. No sería adecuado comparar un modelo cuyo constructo objetivo es intención de uso con otro cuyo resultado central es desempeño organizacional, salvo

que la comparación esté claramente justificada como parte de un sistema más amplio. Tampoco es válido comparar modelos estimados con muestras distintas, instrumentos diferentes o unidades de análisis incompatibles como si fueran alternativas equivalentes. Para que la comparación tenga sentido, debe existir una base común: mismo fenómeno central, mismo constructo objetivo, misma muestra o condiciones comparables, y alternativas derivadas de razonamientos teóricos defendibles. Por ejemplo, si el objetivo es explicar desempeño innovador, puede compararse un modelo directo con capacidades digitales, un modelo mediado por aprendizaje organizacional y un modelo que incorpora cultura innovadora como moderadora. Todos se organizan alrededor del mismo resultado. En cambio, no sería coherente comparar ese modelo con uno centrado en satisfacción del cliente sin explicar la conexión entre ambos resultados. La comparación válida exige que los modelos sean rivales o alternativas del mismo problema, no configuraciones inconexas. Esta regla evita interpretaciones arbitrarias y fortalece la transparencia metodológica. **Cuando el propósito central sea predictivo, la comparación puede fortalecerse mediante CVPAT**, que permite contrastar el desempeño predictivo del modelo PLS-SEM frente a alternativas de referencia, como el promedio de indicadores o un modelo lineal. Si la diferencia promedio de pérdida es negativa y significativa, el modelo ofrece evidencia de mejor desempeño predictivo frente al punto de comparación utilizado (Guenther et al., 2023).

Cuando el estudio tiene orientación predictiva, la comparación de modelos debe complementarse con criterios como PLSpredict, Q^2 _predict, RMSE y MAE, porque el R^2 por sí solo no demuestra poder predictivo. En esta evaluación, Q^2 _predict debe ser mayor que cero para aportar evidencia inicial de predicción; después, el investigador debe revisar la distribución de los errores para decidir si conviene interpretar RMSE, cuando los errores son aproximadamente simétricos, o MAE, cuando dicha simetría no se sostiene. Además, los errores del modelo PLS-SEM deben compararse con los de un modelo lineal de referencia, porque la predicción se defiende mostrando menor error frente a una alternativa razonable. Por ello, si el investigador afirma que su modelo tiene utilidad predictiva, debe evaluar errores de predicción y compararlos con modelos de referencia. La predicción no se demuestra con relaciones significativas, sino con evidencia de que el modelo anticipa valores con menor error que alternativas razonables. Por eso, en estudios PLS-SEM con orientación aplicada, la comparación predictiva debe formar parte del reporte (Shmueli et al., 2019).

En CB-SEM, la comparación de modelos responde a una lógica parcialmente distinta, centrada en el ajuste global y en la comparación de modelos anidados o no anidados. Cuando dos modelos son anidados, es decir, cuando uno puede entenderse como una versión restringida del otro, puede evaluarse si liberar o restringir ciertos parámetros mejora significativamente el ajuste. Por ejemplo, un modelo con una ruta libre puede compararse con otro en el que esa ruta se fija en cero. En estos casos, puede utilizarse la diferencia de chi-cuadrada y grados de libertad, siempre que se cumplan las condiciones metodológicas correspondientes. Cuando los modelos no son anidados, pueden compararse mediante criterios de información, como AIC o BIC, así como mediante índices de ajuste global como CFI, TLI, RMSEA o SRMR. No

obstante, la lógica de fondo es la misma: el modelo con mejores índices no debe aceptarse automáticamente si carece de fundamento conceptual. **En CB-SEM, un buen ajuste estadístico no compensa una mala teoría, una medición débil o una estructura relacional sin sentido**. La comparación debe integrar ajuste, parsimonia, teoría y coherencia del modelo de medición. (Hair et al., 2019).

La comparación de modelos debe evitar el uso oportunista de modificaciones post hoc, porque esa práctica puede generar modelos aparentemente fuertes, pero científicamente frágiles. Un problema frecuente ocurre cuando el investigador estima un modelo inicial, elimina rutas no significativas, agrega relaciones sugeridas por el software, prueba múltiples configuraciones y finalmente reporta solo aquella que produjo mejores indicadores. Esta práctica puede producir un modelo adaptado excesivamente a una muestra específica, con baja replicabilidad y débil fundamento teórico. Si las alternativas fueron formuladas antes del análisis, pueden presentarse como una comparación teóricamente guiada. Si surgieron después de observar resultados, deben declararse como exploratorias. Esta distinción es crucial porque una comparación confirmatoria y una comparación exploratoria no tienen el mismo valor inferencial. La primera contrasta modelos previstos por la teoría; la segunda ayuda a generar hipótesis para investigaciones futuras. **La transparencia exige decir si los modelos comparados fueron definidos antes de la estimación o si emergieron durante el análisis**. En un reporte riguroso, las modificaciones deben documentarse, justificarse y, de ser posible, validarse en nuevas muestras. (Guenther et al., 2023).

La comparación de modelos también puede utilizarse para evaluar si conviene representar un constructo como multidimensional, jerárquico o mediante dimensiones separadas. En administración e innovación, muchos constructos son complejos: transformación digital, sostenibilidad, capacidades dinámicas, madurez organizacional, innovación o desempeño pueden descomponerse en dimensiones. El investigador puede comparar un modelo donde esas dimensiones se mantienen como constructos independientes frente a otro donde se integran en un constructo de segundo orden. La decisión no debe depender solo del resultado estadístico, sino de la teoría del constructo. Si las dimensiones son partes de un dominio común y actúan como facetas de una misma entidad, el modelo jerárquico puede ofrecer mayor parsimonia. Si cada dimensión tiene efectos diferenciados y conceptualmente relevantes sobre el resultado, puede ser más adecuado mantenerlas separadas. **La comparación de modelos ayuda a evaluar cuál especificación representa mejor la teoría y los datos, pero no decide por sí sola la naturaleza conceptual del constructo**. Por ello, el investigador debe justificar si trabaja con factores comunes, modelos compuestos, indicadores formativos o estructuras jerárquicas. (Henseler, 2017).

En modelos de mediación, la comparación de alternativas permite distinguir entre relación directa, mediación parcial y mediación total. Un modelo directo propone que X influye en Y sin mecanismo intermedio. Un modelo con mediación parcial sostiene que X influye en Y directamente y también a través de M. Un modelo con mediación total plantea que el efecto de X sobre Y ocurre principalmente mediante

M, sin un efecto directo relevante una vez incorporado el mediador. Comparar estas alternativas ayuda a determinar si el mediador realmente aporta explicación al fenómeno. Por ejemplo, si las capacidades digitales influyen en el desempeño innovador, el investigador puede comparar si esa relación es directa o si opera a través del aprendizaje organizacional. Si el modelo mediado presenta mejor desempeño y el mecanismo tiene fundamento teórico, entonces la explicación gana profundidad. Sin embargo, si el mediador no mejora la interpretación ni el desempeño del modelo, su inclusión puede ser innecesaria. **La mediación mejora un modelo solo cuando explica un proceso que la relación directa no captura adecuadamente**. Por ello, no debe incorporarse solo para sofisticar el diagrama. (Nitzl et al., 2016).

La comparación de modelos moderados permite valorar si una relación estructural opera de manera estable o si depende de condiciones específicas. Un modelo sin moderación supone que la relación entre X y Y tiene una intensidad relativamente constante en la muestra. Un modelo moderado plantea que esa intensidad cambia según el nivel de Z. Por ejemplo, la relación entre capacidades digitales y desempeño innovador puede ser más fuerte en entornos con alta turbulencia ambiental, o la relación entre actitud hacia una tecnología e intención de uso puede fortalecerse cuando existe apoyo institucional. Comparar ambas configuraciones permite saber si la condición contextual realmente mejora la comprensión del fenómeno. Sin embargo, la moderación debe estar justificada antes del análisis. No es suficiente probar interacciones porque el software lo permite. El moderador debe representar una condición teóricamente relevante que altere la relación principal. **Una moderación aporta valor cuando demuestra que una relación no es universal ni homogénea, sino dependiente del contexto o de características específicas de los participantes u organizaciones**. Si no existe esa justificación, la interacción puede convertirse en ruido estadístico. (Hair et al., 2021).

La comparación de modelos puede ayudar a detectar redundancia conceptual y problemas de diferenciación entre constructos. Cuando dos modelos tienen desempeño similar, pero uno incluye más constructos con contenidos cercanos, el modelo más parsimonioso puede ser preferible. Por ejemplo, utilidad percibida, beneficio percibido, valor percibido y conveniencia percibida podrían presentar solapamientos conceptuales si no se definen con claridad. Mantener todos esos constructos puede aumentar complejidad, colinealidad y problemas de validez discriminante. En cambio, un modelo que conserve solo los constructos conceptualmente necesarios puede ser más claro y estable. Esta comparación no debe basarse únicamente en números, sino también en la revisión de definiciones, indicadores y funciones dentro del modelo. **Cuando dos modelos explican o predicen de manera semejante, la teoría y la parsimonia deben orientar la decisión final**. La comparación, por tanto, no solo permite elegir entre modelos, sino también depurar la arquitectura conceptual y evitar que el modelo se convierta en una acumulación de conceptos próximos. (Henseler et al., 2015).

El reporte de la comparación de modelos debe ser transparente, ordenado y sustantivo. Primero, el investigador debe describir los modelos comparados y explicar

por qué cada uno representa una alternativa teóricamente defendible. Segundo, debe indicar si la comparación fue prevista antes del análisis o si surgió de manera exploratoria. Tercero, debe reportar los criterios utilizados para la comparación, como BIC, AIC, GM, R^2 , Q^2 , RMSE, MAE, Q^2 _predict, CFI, TLI, RMSEA o SRMR, según el enfoque metodológico utilizado. Cuarto, debe presentar los resultados en una tabla clara, evitando saturar el texto con valores innecesarios. Quinto, debe interpretar qué significa que un modelo sea preferible. No basta con afirmar que "el Modelo 2 fue mejor"; se debe explicar por qué esa superioridad importa para el fenómeno. Por ejemplo, si el modelo mediado supera al modelo directo, se puede concluir que el mecanismo intermedio es relevante para comprender la relación. **La comparación de modelos solo aporta conocimiento cuando sus resultados se traducen en interpretación teórica, metodológica y práctica**. De lo contrario, se queda en una tabla de indicadores sin significado sustantivo. (Hair et al., 2021).

Una forma recomendable de presentar la comparación es organizar los modelos como alternativas conceptuales claramente nombradas. Por ejemplo, Modelo 1: relación directa; Modelo 2: relación mediada; Modelo 3: relación mediada con moderación. Después, el investigador puede presentar una tabla con los criterios de comparación y explicar cuál modelo obtiene mejor balance. Si el Modelo 2 presenta menor BIC, mejor Q^2 _predict y errores RMSE/MAE menores que el Modelo 1, pero el Modelo 3 agrega complejidad sin mejorar sustancialmente el desempeño, la interpretación podría ser que el fenómeno se entiende mejor como un proceso mediado, pero que la moderación propuesta no cuenta con evidencia suficiente en ese contexto. Esta forma de reporte muestra madurez metodológica porque reconoce alternativas, evita exagerar resultados y justifica la arquitectura final. **Comparar modelos permite defender el modelo seleccionado con más rigor que presentar una sola configuración como si fuera evidente o incuestionable**. Además, facilita que otros investigadores repliquen, contrasten o amplíen el análisis en nuevos contextos. (Guenther et al., 2023).

La comparación de modelos no debe confundirse con reespecificación indiscriminada del modelo. Reespecificar implica modificar una configuración inicial, por ejemplo, eliminando rutas, agregando relaciones, cambiando indicadores o reorganizando constructos. Comparar modelos implica contrastar alternativas estructurales que pueden haber sido previstas teóricamente. Ambas prácticas pueden ser útiles, pero tienen implicaciones distintas. La reespecificación basada solo en resultados estadísticos debe tratarse con cautela, porque puede reflejar adaptación excesiva a una muestra. En cambio, la comparación de modelos teóricamente previstos permite evaluar explicaciones rivales con mayor legitimidad. Si se realizan cambios post hoc, deben explicarse de manera honesta y no presentarse como confirmaciones definitivas. **Un modelo reespecificado por razones estadísticas requiere validación adicional y debe interpretarse con menor fuerza confirmatoria que un modelo alternativo definido desde la teoría**. Esta distinción es importante para evitar reportes que aparentan rigor, pero ocultan decisiones oportunistas tomadas después de revisar los resultados. (Hair et al., 2019).

En estudios aplicados, la comparación de modelos puede fortalecer la utilidad práctica de la investigación porque permite identificar qué configuración resulta más eficiente para anticipar o explicar decisiones reales. En una institución educativa que desea comprender la intención de uso de IA generativa, puede compararse un modelo basado solo en utilidad percibida con otro que incorpore autoeficacia, confianza y alfabetización en IA. Si el segundo modelo predice mejor, la institución puede diseñar intervenciones más completas, orientadas no solo a mostrar utilidad, sino también a fortalecer habilidades y confianza. Si el modelo simple predice casi igual, puede ser preferible por facilidad de aplicación y comunicación. En empresas, comparar modelos puede ayudar a decidir si el desempeño innovador depende principalmente de capacidades digitales, aprendizaje organizacional o cultura innovadora. **La comparación de modelos convierte el análisis SEM en una herramienta más útil para la toma de decisiones**, porque permite distinguir entre explicaciones teóricamente atractivas y configuraciones realmente útiles para anticipar resultados o intervenir en el fenómeno. Esta utilidad aplicada debe reportarse con prudencia, sin convertir la predicción en promesa determinista. (Shmueli et al., 2019).

El investigador debe reconocer que toda comparación de modelos tiene límites y que el modelo seleccionado solo es preferible frente a las alternativas evaluadas. Un menor BIC, un mejor RMSE, un mayor Q^2 _predict o mejores índices de ajuste no significan que se haya encontrado la única explicación posible del fenómeno. Significan que, con los datos disponibles, en el contexto estudiado y bajo los criterios utilizados, una configuración mostró mejor desempeño relativo. Además, las conclusiones dependen de la calidad del diseño, la muestra, la medición, la ausencia de sesgos graves y la coherencia teórica. Si los datos son transversales, perceptuales o provienen de una sola fuente, la comparación debe interpretarse con cautela. **La comparación de modelos aumenta el rigor, pero no sustituye la calidad del diseño de investigación**. Por ello, el reporte debe reconocer límites y proponer futuras comparaciones en nuevas muestras, contextos o diseños longitudinales. Esta prudencia no debilita el estudio; al contrario, muestra madurez científica y evita afirmaciones excesivas. (Podsakoff et al., 2003).

En síntesis, la comparación de modelos debe entenderse como una práctica de madurez metodológica dentro de SEM, CB-SEM y PLS-SEM. Permite contrastar teorías alternativas, evaluar estructuras directas, mediadas, moderadas o jerárquicas, controlar la complejidad, revisar parsimonia, evitar sobreajuste y seleccionar configuraciones con mejor equilibrio entre teoría, medición, explicación y predicción. En PLS-SEM, criterios como BIC, GM, PLSpredict, RMSE, MAE y Q^2 _predict pueden apoyar la decisión, especialmente cuando el estudio declara orientación predictiva. En CB-SEM, pueden utilizarse diferencias de ajuste, criterios de información e índices globales, siempre con soporte conceptual. La regla final es clara: **el modelo preferible no es necesariamente el más complejo, el más ajustado o el que tiene más rutas significativas, sino el que representa de manera más clara, parsimoniosa, empíricamente defendible y teóricamente coherente el fenómeno investigado**. Así, la comparación de modelos no cierra la investigación como verdad absoluta, sino

que fortalece la argumentación sobre por qué una arquitectura estructural resulta más adecuada que otras alternativas razonables. (Hair et al., 2021).

Conclusiones

El Capítulo 6 permite concluir que **la evaluación SEM/PLS-SEM no termina con la obtención de resultados estadísticos, sino con su interpretación rigurosa, transparente y teóricamente fundamentada**. Un modelo puede presentar coeficientes significativos, valores aceptables de R^2 , indicadores de validez y resultados aparentemente favorables; sin embargo, esos resultados solo adquieren valor científico cuando se conectan nuevamente con el problema de investigación, las hipótesis, la teoría y el contexto empírico. Por ello, el investigador no debe limitarse a copiar salidas del software, sino explicar qué significan los hallazgos, qué relaciones reciben apoyo, cuáles no lo reciben y qué implicaciones tienen para el fenómeno estudiado. **El reporte final es una fase de argumentación científica, no una transcripción mecánica de tablas** (Hair et al., 2019).

Una segunda conclusión es que **el contraste de hipótesis debe interpretarse de manera integral**. Los coeficientes de trayectoria, valores *t*, valores *p* e intervalos de confianza permiten evaluar si una relación propuesta recibe apoyo empírico, pero no sustituyen el razonamiento teórico. Una hipótesis apoyada estadísticamente no necesariamente representa una contribución sustantiva si su efecto es débil, si carece de fundamento conceptual o si no responde al problema central del estudio. Del mismo modo, una hipótesis no apoyada no debe considerarse automáticamente un fracaso, ya que puede revelar límites contextuales, relaciones más complejas, problemas de medición o diferencias entre la teoría y el fenómeno observado. Por ello, **el contraste de hipótesis debe leerse como evidencia empírica situada, no como verdad absoluta** (Hair et al., 2021).

El capítulo también muestra que **los efectos directos, indirectos y totales permiten comprender la arquitectura profunda del modelo estructural**. Los efectos directos indican relaciones inmediatas entre constructos; los efectos indirectos explican mecanismos mediadores; y los efectos totales permiten valorar la influencia global de una variable dentro del sistema. Esta distinción es clave porque muchos fenómenos administrativos, educativos, tecnológicos y organizacionales no ocurren mediante relaciones simples, sino a través de procesos intermedios. Así, una variable puede no tener un efecto directo fuerte, pero sí una influencia relevante mediante un mediador. En consecuencia, **la mediación debe interpretarse como explicación del proceso mediante el cual ocurre una relación**, no como un simple resultado adicional del software (Nitzl et al., 2016).

Otra conclusión relevante es que **la predicción no debe confundirse con la explicación**. Un modelo puede explicar una proporción importante de varianza dentro de la muestra y, aun así, no predecir adecuadamente casos nuevos. Por ello, indicadores como R^2 y Q^2 son útiles, pero no suficientes cuando el estudio declara orientación predictiva. Procedimientos como PLSpredict, junto con métricas como

RMSE, MAE y Q^2_predict, permiten evaluar si el modelo tiene capacidad para anticipar valores con menor error. Esta distinción fortalece el uso de PLS-SEM porque obliga al investigador a demostrar que el modelo no solo tiene relaciones significativas, sino también **utilidad predictiva** para contextos comparables (Shmueli et al., 2019).

Asimismo, el capítulo permite concluir que **la comparación de modelos es una práctica de madurez metodológica**. Comparar modelos no significa probar configuraciones al azar hasta obtener mejores indicadores, sino contrastar alternativas teóricamente defendibles: modelos directos frente a modelos mediados, modelos simples frente a modelos complejos, modelos con o sin moderación, o modelos de primer orden frente a modelos jerárquicos. En este sentido, criterios como BIC, AIC, GM, PLSpredict o índices de ajuste pueden apoyar la decisión, pero nunca reemplazan el fundamento teórico. **El modelo preferible no es necesariamente el más complejo, sino el que ofrece mejor equilibrio entre parsimonia, coherencia conceptual, capacidad explicativa y utilidad predictiva** (Dijkstra & Henseler, 2015).

Finalmente, el Capítulo 6 demuestra que **un reporte SEM/PLS-SEM de calidad debe ser completo, claro, verificable y prudente**. El investigador debe explicar cómo evaluó el modelo de medición, cómo interpretó el modelo estructural, qué hipótesis recibieron apoyo, qué efectos fueron relevantes, qué capacidad predictiva mostró el modelo y si existen modelos alternativos más adecuados. También debe reconocer límites relacionados con muestra, diseño, medición, sesgo de método común, generalización y alcance causal. De esta manera, el capítulo cierra el proceso metodológico mostrando que **la calidad de un modelo SEM no depende solo de sus índices, sino de la coherencia entre teoría, medición, análisis, predicción, comparación e interpretación final** (Gefen et al., 2000). Véase la **Tabla 6.3.**

Tabla 6.3. Robustez, mediación, moderación, MICOM, MGA y reporte

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
AIC	Criterio de información de Akaike utilizado para comparar modelos considerando ajuste y complejidad.	Apoya la selección entre modelos alternativos, especialmente en CB-SEM y modelos no anidados.	Valores menores sugieren mejor equilibrio relativo entre ajuste y parsimonia frente a los modelos comparados.	Hair et al. (2019)
Ajuste global del modelo	Evaluación de qué tan bien el modelo reproduce la estructura observada de los datos, especialmente en CB-SEM.	Permite valorar la adecuación general del modelo teórico frente a los datos observados.	Se interpreta mediante índices como CFI, TLI, RMSEA, SRMR, AIC o BIC, según el enfoque utilizado.	Hair et al. (2019)
Apoyo empírico	Evidencia estadística que	Permite valorar si las relaciones	No equivale a verdad absoluta;	Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	indica si una hipótesis recibe respaldo dentro de una muestra y contexto específicos.	propuestas por la teoría son compatibles con los datos.	debe interpretarse junto con teoría, magnitud del efecto y contexto.	
BIC	Criterio bayesiano de información que compara modelos penalizando la complejidad.	Ayuda a seleccionar el modelo más parsimonioso entre alternativas teóricamente defendibles.	El modelo con menor BIC suele considerarse preferible entre los modelos comparados.	Dijkstra & Henseler (2015); Hair et al. (2021)
Bootstrapping	Procedimiento de remuestreo que estima la estabilidad y significancia de los parámetros del modelo.	Permite evaluar coeficientes de trayectoria, efectos directos, indirectos y totales.	Se usa para obtener valores *t*, valores *p* e intervalos de confianza.	Hair et al. (2021)
Capacidad explicativa	Grado en que el modelo explica la varianza de los constructos endógenos.	Evalúa qué tanto los predictores ayudan a comprender el resultado central.	Se revisa principalmente mediante R^2 y se complementa con f^2.	Hair et al. (2019)
Capacidad predictiva	Habilidad del modelo para anticipar valores de constructos endógenos en casos nuevos o no usados directamente en la estimación.	Permite valorar la utilidad práctica del modelo más allá de la explicación interna.	Debe evaluarse con Q^2, PLSpredict, RMSE, MAE y Q^2_predict.	Shmueli et al. (2019)
Coeficiente de trayectoria / β	Estimación de la fuerza y dirección de una relación estructural entre constructos.	Permite contrastar hipótesis directas dentro del modelo estructural.	Se interpreta por signo, magnitud, significancia y coherencia teórica.	Hair et al. (2021)
Comparación confirmatoria	Comparación de modelos alternativos definidos antes del análisis empírico.	Permite contrastar modelos rivales derivados de teoría previa.	Tiene mayor fuerza inferencial que una comparación exploratoria porque no depende de ajustes post hoc.	Hair et al. (2021)
Comparación de modelos	Evaluación de configuraciones alternativas del modelo estructural.	Permite decidir si un modelo directo, mediado, moderado, jerárquico o alternativo es más adecuado.	El modelo preferible debe equilibrar teoría, parsimonia, explicación y predicción.	Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Comparación exploratoria	Comparación o reespecificación de modelos surgida después de revisar los resultados.	Puede generar nuevas hipótesis o rutas para estudios futuros.	Debe reportarse con cautela y no presentarse como confirmación definitiva.	Guenther et al. (2023)
Contraste de hipótesis	Proceso mediante el cual se evalúa si las relaciones propuestas reciben apoyo empírico.	Traduce la teoría en pruebas estadísticas sobre rutas estructurales.	No debe reducirse a significativo/no significativo; requiere interpretación sustantiva.	Gefen et al. (2000); Hair et al. (2019)
CVPAT	*Cross-validated predictive ability test*; procedimiento para comparar capacidad predictiva entre modelos.	Apoya la comparación predictiva de modelos PLS-SEM.	Se utiliza cuando interesa saber si un modelo predice mejor que otro.	Guenther et al. (2023)
Efecto directo	Relación inmediata entre un constructo antecedente y un constructo dependiente.	Permite evaluar si un predictor influye directamente en un resultado.	Se interpreta mediante coeficiente, valor *t*, valor *p* e intervalo de confianza.	Hair et al. (2021)
Efecto indirecto	Relación que ocurre a través de una variable mediadora.	Permite analizar mecanismos explicativos dentro del modelo.	Es significativo cuando el intervalo de confianza no incluye cero.	Nitzl et al. (2016)
Efecto total	Suma del efecto directo y los efectos indirectos de un constructo sobre otro.	Permite valorar la influencia global de una variable dentro del modelo.	Ayuda a identificar la importancia total de un predictor, aunque parte de su efecto sea mediado.	Nitzl et al. (2016); Hair et al. (2021)
Error predictivo	Diferencia entre los valores observados y los valores predichos por el modelo.	Evalúa el desempeño predictivo del modelo.	Menores errores indican mayor precisión predictiva.	Shmueli et al. (2019)
f^2	Tamaño del efecto de un predictor sobre un constructo endógeno.	Complementa el R^2 al mostrar la contribución individual de cada predictor.	Valores orientativos: .02 pequeño, .15 mediano y .35 grande.	Hair et al. (2019)
GM	Criterio utilizado para comparación de modelos en PLS-SEM.	Apoya la selección entre modelos alternativos considerando desempeño y parsimonia.	Puede utilizarse junto con BIC para comparar configuraciones estructurales.	Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Hipótesis apoyada	Hipótesis cuya relación recibe evidencia empírica favorable.	Permite confirmar provisionalmente una relación propuesta por la teoría.	Debe interpretarse según signo, magnitud, significancia y sentido teórico.	Hair et al. (2021)
Hipótesis no apoyada	Hipótesis cuya relación no recibe evidencia empírica suficiente.	Permite identificar relaciones no confirmadas en la muestra analizada.	No implica fracaso; puede revelar límites contextuales, problemas de medición o relaciones más complejas.	Hair et al. (2019)
Interpretación sustantiva	Explicación del significado teórico, metodológico y práctico de los resultados.	Conecta los resultados estadísticos con el problema de investigación.	Un resultado significativo debe interpretarse según su magnitud, sentido teórico y valor práctico.	Gefen et al. (2000)
Intervalo de confianza	Rango dentro del cual se estima que puede ubicarse el valor poblacional de un parámetro.	Permite evaluar precisión y significancia de coeficientes o efectos indirectos.	Si el intervalo no incluye cero, el efecto suele considerarse significativo.	Hair et al. (2021); Nitzl et al. (2016)
MAE	*Mean Absolute Error*; error absoluto medio de predicción.	Evalúa la precisión predictiva del modelo.	Valores menores indican menor error promedio; debe compararse con modelos de referencia.	Shmueli et al. (2019)
Mediación	Proceso en el que una variable transmite el efecto de un antecedente hacia una consecuencia.	Explica el mecanismo mediante el cual ocurre una relación.	Puede ser parcial o total; se interpreta mediante efectos indirectos.	Nitzl et al. (2016)
Modelo alternativo	Configuración distinta del modelo original, derivada de otra teoría, estructura o supuesto.	Permite comparar explicaciones rivales o estructuras más parsimoniosas.	Debe estar teóricamente justificado y no surgir solo de prueba y error.	Hair et al. (2021)
Modelo anidado	Modelo que representa una versión restringida de otro modelo más amplio.	Permite comparar estructuras mediante diferencias de ajuste, especialmente en CB-SEM.	Puede evaluarse mediante diferencias de Chi-cuadrada y grados de libertad cuando corresponde.	Hair et al. (2019)
Modelo de referencia	Modelo simple utilizado como	Permite evaluar si el modelo SEM	En PLSpredict puede	Shmueli et al. (2019)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	punto de comparación predictiva.	predice mejor que una alternativa básica.	compararse con modelos como LM; si PLS-SEM tiene menor error, muestra mejor desempeño predictivo.	
Modelo directo	Modelo donde un antecedente se relaciona directamente con una variable dependiente.	Sirve como configuración básica para evaluar relaciones simples.	Puede compararse con modelos mediados o moderados.	Hair et al. (2021)
Modelo jerárquico	Modelo donde un constructo superior se representa mediante dimensiones de primer orden.	Permite evaluar constructos multidimensionales.	Debe conservarse si mejora la representación conceptual y la parsimonia.	Henseler (2017)
Modelo mediado	Modelo que incorpora una variable intermedia para explicar cómo ocurre una relación.	Permite analizar mecanismos explicativos.	Es preferible al modelo directo si el mediador tiene fundamento teórico y mejora la interpretación.	Nitzl et al. (2016)
Modelo moderado	Modelo que incorpora una variable que modifica la intensidad o dirección de una relación.	Permite identificar condiciones bajo las cuales cambia una relación estructural.	Debe usarse cuando la teoría justifica que el efecto no es homogéneo.	Hair et al. (2021)
Modelo no anidado	Modelo alternativo que no es una versión restringida directa de otro.	Permite comparar explicaciones distintas sobre el mismo fenómeno.	Puede compararse mediante AIC, BIC u otros criterios de información.	Hair et al. (2019)
Modelo parsimonioso	Modelo que incluye solo los constructos y relaciones necesarios para responder la pregunta de investigación.	Evita complejidad innecesaria, redundancia y sobreajuste.	Es preferible si explica o predice adecuadamente con menor complejidad.	Hair et al. (2021)
Modelo reespecificado	Modelo modificado después de revisar resultados preliminares.	Puede ajustar relaciones, rutas o constructos, pero requiere justificación.	Si surge post hoc, debe reportarse como exploratorio y validarse con cautela.	Hair et al. (2019)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Modelo rival	Modelo alternativo que compite con el modelo propuesto para explicar o predecir el mismo fenómeno.	Fortalece la defensa del modelo seleccionado.	Debe compartir constructo objetivo, muestra comparable y fundamento conceptual.	Reinartz et al. (2009)
Moderación	Efecto en el que una variable modifica la relación entre un predictor y una variable dependiente.	Permite analizar cuándo, para quién o bajo qué condiciones cambia una relación.	Se interpreta como interacción; debe tener fundamento teórico.	Hair et al. (2021)
Parsimonia	Principio metodológico que recomienda incluir solo los constructos y relaciones necesarios.	Ayuda a evitar modelos sobrecargados, redundantes o difíciles de interpretar.	Un modelo más simple puede ser preferible si explica o predice de forma suficiente.	Hair et al. (2021)
p valor	Probabilidad asociada a una prueba estadística bajo la hipótesis nula.	Ayuda a valorar la significancia de rutas y efectos.	$p < .05$ suele interpretarse como significativo, pero debe complementarse con magnitud y teoría.	Gefen et al. (2000); Hair et al. (2019)
PLSpredict	Procedimiento para evaluar predicción fuera de muestra en PLS-SEM.	Permite analizar si el modelo predice valores de casos no usados directamente en la estimación.	Se interpreta mediante RMSE, MAE, Q^2 _predict y comparación con modelos de referencia.	Shmueli et al. (2019)
Poder predictivo	Capacidad del modelo para anticipar resultados empíricos con precisión.	Evalúa la utilidad aplicada del modelo.	No se demuestra solo con R^2; requiere evaluación predictiva específica.	Shmueli et al. (2019)
Prudencia causal	Cuidado al interpretar relaciones estructurales como causales, especialmente con datos transversales.	Evita afirmaciones excesivas sobre causalidad cuando el diseño no lo permite.	Conviene hablar de relación estructural, efecto estimado o influencia teóricamente esperada.	Shmueli (2010)
Q^2	Índice de relevancia predictiva tradicional.	Evalúa si el modelo tiene capacidad predictiva básica sobre constructos endógenos.	$Q^2 > 0$ indica relevancia predictiva.	Hair et al. (2019); Shmueli et al. (2019)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Q^2 _predict	Índice de evaluación predictiva asociado a PLSpredict.	Permite valorar si el modelo supera una predicción ingenua o de referencia.	Valores positivos sugieren capacidad predictiva frente a un punto de referencia básico.	Shmueli et al. (2019)
R^2	Coeficiente de determinación que indica la varianza explicada de un constructo endógeno.	Evalúa la capacidad explicativa interna del modelo.	Valores orientativos: .25 débil, .50 moderado y .75 sustancial. No prueba por sí solo poder predictivo.	Hair et al. (2019); Hair et al. (2021)
Reporte SEM/PLS-SEM	Presentación ordenada, transparente y verificable de los resultados del modelo.	Permite comunicar medición, estructura, hipótesis, efectos, predicción y comparación.	No debe copiar salidas del software; debe interpretar resultados con teoría y contexto.	Hair et al. (2019)
RMSE	*Root Mean Square Error*; raíz del error cuadrático medio.	Mide la precisión predictiva penalizando errores grandes.	Valores menores indican mejor desempeño predictivo; debe compararse con modelos de referencia.	Shmueli et al. (2019)
Significancia estadística	Evidencia de que un coeficiente o efecto difiere estadísticamente de cero.	Permite valorar apoyo empírico para rutas o efectos.	No equivale automáticamente a relevancia teórica o práctica.	Hair et al. (2021)
Sobreajuste	Situación en la que el modelo se adapta demasiado a una muestra específica.	Puede inflar indicadores internos y reducir generalización.	Se evita con parsimonia, validación predictiva y comparación de modelos.	Guenther et al. (2023)
Tamaño del efecto	Magnitud sustantiva de la contribución de una variable.	Permite valorar relevancia práctica más allá de la significancia.	En PLS-SEM suele revisarse con f^2 .	Hair et al. (2019)
Transparencia del reporte	Presentación clara de decisiones metodológicas, resultados, limitaciones y criterios de evaluación.	Permite evaluar, replicar o cuestionar el análisis realizado.	El reporte debe explicar qué se hizo, por qué se hizo y cómo se interpretaron los resultados.	Hair et al. (2019)
Valor t	Estadístico usado para evaluar si un coeficiente difiere	Permite contrastar hipótesis estructurales.	En prueba bilateral, valores superiores a 1.96 suelen asociarse	Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	significativamente de cero.		con significancia al 5%.	

Fuente: recopilación y elaboración propia

CAPÍTULO 7. Del modelo SEM al producto de investigación

El Capítulo 7, **"Del modelo SEM al producto de investigación"**, cierra la ruta metodológica del libro al mostrar que un modelo estructural no debe entenderse únicamente como un diagrama, una estimación estadística o una salida de software, sino como un **producto científico integral**. En los capítulos anteriores se explicó cómo una idea inicial se transforma en fenómeno investigable, cómo el fenómeno se convierte en problema, cómo el problema da lugar a un sistema conceptual, cómo la teoría permite construir un marco relacional, cómo los conceptos se traducen en constructos medibles y cómo el modelo se evalúa, contrasta, predice, compara y reporta. Este último capítulo integra todo ese proceso y enfatiza que **la calidad de un modelo SEM/PLS-SEM depende de la coherencia acumulada entre problema, teoría, medición, análisis e interpretación**. Por ello, el modelo final no debe aparecer como una figura aislada, sino como la representación visible de una cadena de decisiones científicas previamente justificadas (Hair et al., 2019

El capítulo inicia con la **integración final del proceso: de la idea al modelo evaluado**. Esta sección recupera la ruta completa del libro y muestra que cada etapa depende de la anterior. Una idea mal delimitada produce un fenómeno ambiguo; un fenómeno ambiguo genera un problema débil; un problema débil deriva en una pregunta estructural poco clara; una pregunta poco clara conduce a constructos mal definidos; y constructos mal definidos producen modelos difíciles de interpretar. En sentido contrario, cuando el investigador avanza con rigor desde la idea hasta el modelo evaluado, logra construir una arquitectura conceptual, metodológica y empírica defendible. **El modelo SEM/PLS-SEM no inicia en el software, sino en la capacidad del investigador para formular una pregunta estructural pertinente y traducirla en constructos, indicadores, hipótesis y criterios de evaluación** (Gefen et al., 2000).

Posteriormente, el capítulo desarrolla la **construcción del modelo SEM como producto científico**. Esta idea es central porque permite comprender que el modelo no es solo una herramienta de análisis, sino una forma organizada de producir conocimiento. Un modelo científico debe responder a un vacío, explicar o predecir un resultado relevante, justificar la selección de variables, definir la función de cada constructo y mostrar trazabilidad entre teoría, hipótesis y evidencia empírica. En este sentido, el modelo cumple una doble función: por una parte, sintetiza una explicación teórica; por otra, permite someter esa explicación a evaluación empírica. **Un modelo estructural tiene valor científico cuando cada constructo, cada indicador y cada relación pueden defenderse desde el problema de investigación y no solo desde los resultados estadísticos** (Whetten, 1989).

El tercer eje del capítulo se concentra en la **redacción del apartado metodológico para tesis, artículo o capítulo de libro**. Esta sección muestra que la metodología no debe redactarse como una descripción administrativa de procedimientos, sino como una justificación ordenada de decisiones. El investigador debe explicar el enfoque, el diseño, la población, la unidad de análisis, la muestra, el instrumento, la operacionalización de constructos, el tipo de modelo de medición, la técnica SEM/PLS-SEM seleccionada, el software utilizado y los criterios de evaluación del modelo de medición y estructural. **Una metodología sólida permite que el lector comprenda qué se hizo, por qué se hizo, cómo se hizo y bajo qué criterios se interpretaron los resultados**. En consecuencia, el apartado metodológico funciona como un ejercicio de transparencia entre el investigador y la comunidad académica (Bem, 2004).

El cuarto componente aborda la **presentación e interpretación de resultados SEM/PLS-SEM**. En este punto, el capítulo insiste en que reportar resultados no significa copiar tablas del software ni declarar de manera mecánica si las hipótesis fueron apoyadas o no apoyadas. La presentación debe seguir una secuencia lógica: primero el modelo de medición; después el modelo estructural; luego, el contraste de hipótesis y la interpretación de efectos directos, indirectos y totales; y, cuando corresponda, el poder predictivo y la comparación de modelos. **Interpretar resultados significa conectar coeficientes, índices y efectos con la teoría, el problema, la**

pregunta de investigación y el contexto empírico. Así, el investigador evita tanto la sobreinterpretación de resultados débiles como la subutilización de hallazgos relevantes (Hair et al., 2021).

Finalmente, el capítulo cierra con la **discusión, contribuciones, limitaciones y futuras líneas de investigación**. Esta sección convierte los resultados en aportación académica. La discusión debe explicar qué significan los hallazgos, cómo dialogan con la literatura previa, qué relaciones fueron apoyadas, cuáles no lo fueron y qué implicaciones tienen para la teoría y la práctica. Las contribuciones pueden ser teóricas, metodológicas, empíricas o prácticas, pero deben derivarse directamente del modelo evaluado. Las limitaciones, por su parte, delimitan el alcance de las conclusiones y muestran prudencia científica. Las futuras líneas de investigación proyectan el estudio hacia nuevas muestras, contextos, diseños, variables o modelos alternativos. **Un producto de investigación de calidad no concluye con resultados estadísticos favorables, sino con una interpretación prudente, útil y científicamente defendible del modelo construido** (Corley & Gioia, 2011).

En conjunto, el Capítulo 7 permite comprender que el propósito final del libro no es únicamente enseñar a estimar modelos SEM/PLS-SEM, sino formar **criterio investigador** para construir, justificar, evaluar, interpretar y comunicar modelos estructurales. La destreza técnica es necesaria, pero insuficiente si no existe claridad conceptual, consistencia metodológica y capacidad argumentativa. Por ello, este capítulo funciona como cierre integrador: muestra cómo pasar del modelo evaluado al producto académico publicable, ya sea en forma de tesis, artículo científico, capítulo de libro o informe de investigación aplicada. **El verdadero dominio de SEM/PLS-SEM no consiste solo en ejecutar un modelo, sino en convertirlo en conocimiento estructurado, verificable y comunicable** (Guenther et al., 2023).

Fin del proceso: de la idea al modelo evaluado

La integración final del proceso de investigación estructural consiste en comprender que un modelo SEM/PLS-SEM no aparece al final como un producto aislado, sino como resultado acumulativo de una cadena de decisiones conceptuales, metodológicas y empíricas. Desde esta perspectiva, el investigador no debe pensar el modelo como un diagrama que se dibuja cuando ya se tienen datos, ni como una salida generada por software, sino como una construcción progresiva que inicia con una idea, se delimita como fenómeno, se problematiza científicamente, se convierte en pregunta estructural, se organiza en un sistema conceptual, se transforma en marco relacional, se operacionaliza mediante constructos e indicadores, se evalúa en términos de medición y estructura, y finalmente se contrasta, interpreta, predice, compara y reporta. Esta secuencia es importante porque evita uno de los errores más frecuentes en investigación aplicada: comenzar por la técnica antes de haber construido el objeto de estudio. En SEM/PLS-SEM, el software puede estimar relaciones, calcular cargas, generar coeficientes y producir indicadores, pero no puede decidir por sí mismo qué fenómeno merece estudiarse, qué problema tiene relevancia

científica, qué variable dependiente organiza el modelo, qué constructos son pertinentes ni qué relaciones poseen sentido teórico. Por ello, la integración final del proceso exige recuperar la lógica completa del libro: **primero se piensa el modelo, después se mide, luego se estima y finalmente se interpreta**. Esta visión es coherente con la idea de que PLS-SEM debe utilizarse y reportarse con base en criterios conceptuales, metodológicos y analíticos claramente justificados, y no como una rutina mecánica de estimación (Hair et al., 2019).

El recorrido inicia con la idea, pero la idea todavía no es investigación. Una idea puede surgir de una inquietud académica, de un problema organizacional, de una lectura teórica, de una observación empírica, de una necesidad profesional o de una oportunidad de innovación. Sin embargo, mientras permanezca como una formulación amplia —por ejemplo, “quiero estudiar innovación”, “me interesa la transformación digital” o “deseo analizar sostenibilidad empresarial”— todavía no puede convertirse en modelo SEM. La idea necesita ser depurada hasta transformarse en un fenómeno investigable. Esto implica precisar qué ocurre, dónde ocurre, a quién afecta, por qué importa y bajo qué condiciones puede ser observado. En ciencias de la administración, esta conversión resulta esencial porque los fenómenos suelen ser complejos, multidimensionales y contextuales. La innovación, por ejemplo, puede estudiarse como resultado, capacidad, proceso, cultura, comportamiento o estrategia; cada decisión conduce a variables, indicadores e hipótesis diferentes. Por ello, la integración final exige recordar que el modelo evaluado solo será tan sólido como la claridad inicial con que se delimitó la idea. Si la idea fue ambigua, el fenómeno será débil; si el fenómeno fue impreciso, el problema será difuso; si el problema fue difuso, la pregunta estructural será inestable; y si la pregunta fue inestable, el modelo tendrá relaciones difíciles de defender. **La calidad del modelo comienza antes del modelo** (Whetten, 1989).

El segundo momento de integración consiste en transformar el fenómeno en problema de investigación. Un fenómeno puede ser observable y relevante, pero no necesariamente constituye un problema científico. Para adquirir ese carácter, debe mostrar una tensión: algo que no se ha explicado suficientemente, una relación poco comprendida, un vacío empírico en cierto contexto, una limitación metodológica, una contradicción en la literatura o una necesidad práctica que requiere interpretación conceptual. En esta fase, el investigador debe evitar que el problema sea únicamente una descripción de la realidad. Decir que “las empresas enfrentan dificultades para innovar” puede ser relevante, pero aún no expresa una estructura investigable. En cambio, plantear que “no se comprende suficientemente cómo las capacidades digitales se relacionan con el desempeño innovador en pymes de economías emergentes” ya ofrece una ruta conceptual más clara. Allí aparecen una variable resultado, posibles antecedentes, un contexto y una necesidad de explicación. Esta transformación es crucial porque el problema funciona como matriz del modelo. Si el problema no contiene una tensión relacional, el modelo posterior tenderá a ser una acumulación de variables. **Un problema bien formulado no solo justifica el estudio; también anticipa la arquitectura del modelo estructural**. De este modo, la integración final exige revisar si el modelo evaluado responde realmente al problema

inicial o si, en el camino, se convirtió en un ejercicio estadístico desconectado de la pregunta original (Gregor, 2006).

La pregunta estructural representa el tercer momento del proceso, porque convierte el problema en una orientación analítica concreta. Una buena pregunta para SEM/PLS-SEM no se limita a describir un fenómeno, sino que expresa relaciones entre constructos. Preguntas como "¿qué es la transformación digital?" o "¿cuáles son las características de la innovación?" pueden ser útiles en estudios conceptuales o exploratorios, pero no bastan para construir un modelo estructural. En cambio, preguntas como "¿en qué medida las capacidades digitales influyen en el desempeño innovador?" o "¿qué papel mediador desempeña el aprendizaje organizacional en la relación entre capacidades digitales y desempeño innovador?" ya contienen una lógica SEM. En ellas se identifica una variable dependiente, uno o más antecedentes, posibles mecanismos y un sentido relacional. La pregunta debe ser suficientemente clara para orientar objetivos, hipótesis, constructos, indicadores, técnica de análisis y criterios de interpretación. En la integración final, el investigador debe comprobar que la pregunta y el modelo evaluado coinciden. Si la pregunta se orientaba a explicación, el reporte debe interpretar mecanismos y relaciones; si se orientaba a predicción, debe incluir evaluación predictiva; si combinaba ambas finalidades, debe reportar tanto capacidad explicativa como poder predictivo. **La pregunta estructural es la brújula del modelo; sin ella, el análisis pierde dirección científica** (Shmueli, 2010).

Así, se debe proceder a la construcción del sistema conceptual, donde el investigador organiza el problema en una primera arquitectura de conceptos, variables, antecedentes, consecuencias, mecanismos y condiciones. Este sistema conceptual no es todavía el modelo estadístico, pero prepara su lógica. Su función es ordenar el fenómeno antes de convertirlo en rutas, hipótesis e indicadores. En esta fase, el investigador debe decidir qué variable dependiente organiza el estudio, qué variables explicativas tienen fundamento, qué relaciones directas son plausibles, qué mediadores pueden explicar mecanismos y qué moderadores pueden representar condiciones contextuales. El sistema conceptual también ayuda a evitar el coleccionismo de variables, es decir, la inclusión de constructos solo porque son populares o aparecen en la literatura. Un modelo SEM no mejora por acumular términos, sino por organizar relaciones necesarias. En esta etapa, la parsimonia comienza a operar como criterio de calidad. Un sistema conceptual fuerte permite que cada variable tenga una función: explicar, ser explicada, mediar, moderar o controlar. Si una variable no cumple ninguna función clara, probablemente no pertenece al modelo. En la integración final, este punto es decisivo porque permite evaluar si el modelo final conserva la estructura conceptual inicial o si incorporó relaciones sin fundamento. **La coherencia del modelo depende de que cada constructo tenga una función conceptual precisa dentro del sistema** (Corley & Gioia, 2011).

El marco relacional constituye el siguiente momento del proceso, porque transforma el sistema conceptual en relaciones estructurales defendibles. Aquí la teoría deja de ser un conjunto de conceptos y se convierte en una red de relaciones esperadas. El investigador debe justificar por qué un constructo antecede a otro, qué

dirección tiene la relación, si el vínculo es positivo o negativo, si existe un mecanismo mediador y si alguna condición puede modificar la intensidad del efecto. En este punto, las flechas del modelo no deben entenderse como recursos gráficos, sino como afirmaciones teóricas. Cada flecha expresa una proposición: se espera que X influya en Y, que M transmita el efecto de X hacia Y, o que Z modifique la relación entre X y Y. Esta etapa conecta directamente con la formulación de hipótesis. Una hipótesis estructural bien formulada debe tener constructos definidos, dirección esperada, fundamento teórico y posibilidad de contraste empírico. Por ello, la integración final exige revisar si el modelo evaluado conserva trazabilidad entre teoría, hipótesis y rutas. Si una flecha no puede justificarse desde la teoría, su significancia estadística tendrá poco valor científico. **El marco relacional es el puente entre pensar el fenómeno y estimar el modelo** (Chin, 1998).

De esta forma, se procede a la conversión de conceptos en variables, constructos, dimensiones e indicadores. Esta fase es delicada porque define si el modelo podrá medirse con validez. Un concepto como confianza, satisfacción, aprendizaje organizacional, desempeño innovador o capacidad digital no puede entrar al modelo únicamente por su nombre; debe definirse, delimitarse y operacionalizarse. La diferencia entre concepto, variable y constructo es fundamental. El concepto nombra una idea; la variable expresa una propiedad susceptible de variación; el constructo representa una entidad teórica no observable directamente, inferida mediante indicadores. En esta fase, el investigador debe definir el dominio conceptual del constructo, decidir si será reflectivo, formativo o compuesto, identificar posibles dimensiones, seleccionar indicadores y redactar ítems congruentes con la unidad de análisis. Un error en esta etapa puede afectar todo el modelo posterior. Si los indicadores no representan el constructo, si el constructo se solapa con otro, o si se confunden antecedentes con dimensiones, los resultados estadísticos serán difíciles de interpretar. Por ello, en la integración final se debe reconocer que **la medición no es un trámite posterior, sino una condición constitutiva de la calidad del modelo**. Un modelo estructural solo puede interpretarse si sus constructos fueron adecuadamente definidos y medidos (Churchill, 1979).

La especificación del tipo de constructo representa una decisión central dentro de la integración del proceso. En modelos reflectivos, el constructo se considera la causa de sus indicadores; por ejemplo, la satisfacción se manifiesta en ítems relacionados con agrado, cumplimiento de expectativas y evaluación positiva. En modelos formativos, los indicadores forman el constructo; por ejemplo, un índice de capacidad digital puede estar constituido por infraestructura tecnológica, habilidades humanas, cultura digital y procesos automatizados. En modelos compuestos, los indicadores se integran como componentes de una entidad construida analíticamente. Esta distinción tiene consecuencias directas en la evaluación posterior. No se evalúa igual un constructo reflectivo que uno formativo o compuesto. Si el investigador especifica mal el tipo de constructo, puede aplicar criterios inadecuados y generar conclusiones erróneas. Por ejemplo, exigir alta correlación interna a indicadores formativos puede ser incorrecto, mientras que ignorar la consistencia interna en escalas reflectivas puede debilitar la validez de la medición. En la integración final, el

lector debe comprender que la especificación conceptual precede a la evaluación estadística. **La pregunta no es qué criterio pide el software, sino qué tipo de constructo fue definido por la teoría** (Jarvis et al., 2003).

Posteriormente, se debe evaluar el modelo de medición, ya que las relaciones estructurales solo son interpretables si los constructos tienen calidad empírica suficiente. En PLS-SEM, los modelos reflectivos suelen evaluarse mediante cargas externas, confiabilidad interna, confiabilidad compuesta, rho_A, validez convergente mediante AVE y validez discriminante mediante criterios como HTMT. En modelos formativos o compuestos, la atención se desplaza hacia colinealidad, pesos, cargas, relevancia teórica e importancia de indicadores. Esta fase no debe reducirse a cumplir umbrales de manera mecánica. Un indicador con carga baja puede eliminarse si debilita la medición y no es esencial para el dominio conceptual, pero también puede conservarse si representa una dimensión teóricamente relevante. Del mismo modo, un HTMT aceptable ayuda a mostrar que dos constructos son distintos, pero la diferenciación debe comenzar desde la definición conceptual. En la integración final, el investigador debe reconocer que la evaluación de medición no es independiente de las etapas anteriores: depende de cómo se definieron constructos, dimensiones e indicadores. **La calidad empírica del modelo de medición confirma o cuestiona la calidad conceptual de la operacionalización** (Henseler et al., 2015).

El siguiente momento, corresponde a la evaluación del modelo estructural, donde se analizan las relaciones entre constructos. Una vez que el modelo de medición ofrece evidencia suficiente, el investigador puede interpretar rutas, coeficientes, colinealidad estructural, R^2 , f^2 , Q^2 y significancia de relaciones. El coeficiente de trayectoria indica la dirección y fuerza de una relación; el valor t y el valor p ayudan a evaluar si el efecto difiere estadísticamente de cero; el intervalo de confianza permite valorar precisión; el R^2 muestra la varianza explicada del constructo endógeno; el f^2 indica la contribución individual de un predictor; y el Q^2 aporta evidencia de relevancia predictiva. Sin embargo, cada criterio debe interpretarse en relación con la teoría y la pregunta de investigación. Una relación significativa pero débil puede tener poco valor sustantivo; una relación no significativa puede revelar límites contextuales o mecanismos no considerados; un R^2 elevado puede mostrar capacidad explicativa interna, pero no necesariamente poder predictivo externo. En la integración final, el investigador debe evitar lecturas automáticas. **Evaluar el modelo estructural significa interpretar un sistema de relaciones, no solo reportar números** (Hair et al., 2021).

De esta forma, llegamos al contraste de hipótesis, donde el modelo relacional se somete a evidencia empírica. Las hipótesis representan la forma evaluable de la teoría: cada una expresa una relación esperada entre constructos. En PLS-SEM, el contraste suele apoyarse en *bootstrapping* para obtener valores t, valores p e intervalos de confianza. No obstante, el contraste de hipótesis no debe reducirse a declarar si una hipótesis fue apoyada o no apoyada. El investigador debe interpretar el signo del coeficiente, su magnitud, su coherencia con la teoría, su relevancia práctica, el tamaño del efecto y su posición dentro del modelo. Una hipótesis apoyada puede

fortalecer el marco teórico, pero también puede ser trivial si su efecto es mínimo. Una hipótesis no apoyada puede ser valiosa si revela que una relación esperada no opera en cierto contexto, si sugiere una mediación omitida o si muestra diferencias entre poblaciones. En la integración final, el contraste se entiende como un diálogo entre teoría y datos. **Los resultados no hablan por sí solos; deben ser interpretados desde la arquitectura conceptual que les dio origen** (Gefen et al., 2000).

A esta altura, se deben integrar los efectos directos, indirectos y totales, especialmente cuando el modelo incorpora mediación. Muchos fenómenos en administración no se explican mediante vínculos simples, sino mediante procesos. Una capacidad puede influir en un resultado a través de aprendizaje; el liderazgo puede incidir en el desempeño mediante compromiso; la confianza puede fortalecer la intención de uso a través de reducción de riesgo. Por ello, la mediación permite explicar cómo o por qué ocurre una relación. El efecto directo muestra la relación inmediata entre X y Y; el efecto indirecto muestra la relación transmitida por M; y el efecto total integra ambas rutas. Esta distinción es crucial porque una variable puede no presentar un efecto directo fuerte y, sin embargo, ser importante mediante efectos indirectos. La interpretación de la mediación debe estar guiada por teoría, no por búsqueda de significancia. En la integración final, el investigador debe conectar la mediación con el problema inicial: ¿qué mecanismo se buscaba comprender?, ¿el mediador explica realmente el proceso?, ¿la evidencia empírica sostiene esa explicación? **La mediación agrega valor cuando convierte una relación estadística en una explicación del proceso** (Nitzl et al., 2016).

Con lo anterior, ya estamos en la posibilidad de la evaluación del poder predictivo, especialmente relevante cuando el estudio declara orientación causal-predictiva. En PLS-SEM, es frecuente reportar R^2 como evidencia de capacidad explicativa; sin embargo, un R^2 alto no demuestra por sí solo que el modelo prediga bien nuevos casos. La predicción exige evaluar qué tan bien el modelo anticipa valores observados que no fueron usados directamente en la estimación. Procedimientos como PLSpredict permiten valorar errores predictivos mediante RMSE, MAE y Q^2 _predict, comparando el desempeño del modelo frente a puntos de referencia. Esta fase es importante porque distingue entre explicación dentro de la muestra y predicción fuera de la muestra. Un modelo puede explicar bien los datos disponibles y aun así fallar al anticipar nuevos casos. Por ello, si el investigador afirma que su modelo sirve para anticipar intención de uso, desempeño, innovación o satisfacción, debe demostrarlo con evidencia predictiva específica. En la integración final, la predicción no reemplaza la teoría, pero amplía la utilidad del modelo. **Un modelo predictivamente útil no solo explica relaciones, sino que reduce errores al anticipar resultados comparables** (Shmueli et al., 2019).

Lograr lo anterior, nos permite la comparación de modelos, una fase de madurez metodológica. Comparar modelos no significa probar configuraciones al azar, sino contrastar alternativas teóricamente defendibles. El investigador puede comparar un modelo directo con uno mediado, un modelo simple con uno moderado, un modelo con dimensiones separadas frente a uno jerárquico, o una estructura

parsimoniosa frente a una más compleja. La comparación permite valorar cuál arquitectura ofrece mejor equilibrio entre teoría, parsimonia, capacidad explicativa y poder predictivo. En PLS-SEM, criterios como BIC, GM, PLSpredict, RMSE, MAE o Q^2 _predict pueden apoyar la decisión. En esta etapa, la regla central es que el modelo preferible no es necesariamente el más grande, sino el más defendible. Un modelo complejo puede parecer atractivo, pero si no mejora la explicación ni la predicción, puede ser menos adecuado que uno más simple. En la integración final, la comparación ayuda a justificar la arquitectura seleccionada y a mostrar que el modelo final fue evaluado frente a alternativas razonables. **Comparar modelos fortalece la credibilidad de la propuesta estructural** (Dijkstra & Henseler, 2015).

Con los datos obtenidos es posible realizar el reporte académico, donde el análisis se convierte en producto de investigación. Reportar no significa copiar salidas del software, sino construir una narración ordenada, transparente y verificable. Un reporte sólido debe explicar el diseño, la muestra, el instrumento, los constructos, el tipo de modelo, la técnica utilizada, el software, los criterios de evaluación, los resultados de medición, los resultados estructurales, las hipótesis apoyadas y no apoyadas, los efectos directos e indirectos, el poder predictivo, la comparación de modelos y las limitaciones. Además, debe conectar los hallazgos con la teoría y el problema de investigación. La transparencia es esencial: el lector debe poder comprender qué se hizo, por qué se hizo, cómo se evaluó y qué significan los resultados. En la integración final, el reporte es el momento en que el investigador muestra dominio metodológico y capacidad interpretativa. Un buen reporte no exagera hallazgos, no oculta resultados débiles y no convierte significancia estadística en causalidad absoluta. **La calidad del producto de investigación depende tanto del análisis como de la forma en que se argumenta y comunica** (Bem, 2004).

Como acto de reflexión, volvemos a la teoría para discutir contribuciones. Después de estimar, contrastar y reportar, el investigador debe responder qué aporta el modelo al conocimiento. La contribución puede ser teórica, si confirma, amplía o cuestiona relaciones existentes; metodológica, si mejora la forma de medir o modelar un constructo; empírica, si aporta evidencia en un contexto poco estudiado; o práctica, si ayuda a orientar decisiones en organizaciones, instituciones o mercados. Esta discusión no debe inventarse al final; debe estar conectada con el vacío identificado al inicio. Si el problema señalaba que no se comprendía un mecanismo, la contribución debe explicar cómo el modelo permitió comprenderlo. Si el vacío era empírico, la contribución debe destacar la evidencia contextual. Si era metodológico, debe señalar cómo la medición, comparación o predicción aportan al campo. En la integración final, la discusión cierra el ciclo entre idea y modelo evaluado. **Un modelo SEM aporta científicamente cuando sus resultados responden al vacío que justificó el estudio** (Corley & Gioia, 2011).

Finalmente, se exige reconocer límites y formular futuras líneas de investigación. Todo modelo tiene límites: puede depender de una muestra específica, de un diseño transversal, de datos perceptuales, de una sola fuente, de constructos medidos mediante escalas, de supuestos de estimación o de un contexto particular.

Reconocer estos límites no debilita el estudio; lo fortalece, porque muestra prudencia metodológica. En SEM/PLS-SEM, resulta especialmente importante evitar afirmaciones causales excesivas cuando el diseño no permite sostener causalidad fuerte. También debe señalarse si existen riesgos de sesgo de método común, endogeneidad, colinealidad, limitaciones de muestra o falta de validación externa. Las futuras líneas pueden proponer estudios longitudinales, muestras comparativas, análisis multigrupo, modelos alternativos, nuevas variables mediadoras o moderadoras, o validación predictiva en otros contextos. En la integración final, los límites permiten entender que el modelo evaluado no es una verdad definitiva, sino una representación empíricamente sustentada dentro de condiciones específicas. **La prudencia interpretativa es parte de la calidad científica del modelo** (Podsakoff et al., 2024).

En conjunto, la integración final del proceso muestra que el camino de la idea al modelo evaluado es una secuencia acumulativa y no una suma de capítulos aislados. La idea aporta el punto de partida; el fenómeno delimita la realidad observable; el problema identifica la tensión científica; la pregunta estructura la dirección analítica; el sistema conceptual organiza variables y relaciones; el marco relacional convierte teoría en hipótesis; los constructos e indicadores hacen posible la medición; el modelo de medición evalúa la calidad de la operacionalización; el modelo estructural contrasta relaciones; la predicción valora utilidad anticipatoria; la comparación examina alternativas; y el reporte convierte el análisis en conocimiento comunicable. Cada etapa depende de la anterior y prepara la siguiente. Si una fase se debilita, el modelo completo pierde solidez. Por ello, el propósito del capítulo no es repetir el libro, sino mostrar su lógica integrada. **Un modelo SEM/PLS-SEM de calidad es resultado de coherencia acumulada: conceptual, metodológica, empírica e interpretativa** (Hair et al., 2021).

La integración final también permite comprender que el modelo evaluado es más que un resultado estadístico: es un producto científico. Esto significa que debe poder defenderse ante lectores, revisores, directores de tesis, comités académicos o pares investigadores. **Para ello, el investigador debe demostrar trazabilidad**: de dónde salió la variable dependiente, por qué se eligieron esos antecedentes, cómo se justificaron las hipótesis, de qué manera se definieron los constructos, con qué criterios sedefiniieron los indicadores, cómo se evaluó la medición, cómo se interpretaron relaciones, cómo se examinó la predicción y por qué el modelo final es preferible frente a alternativas posibles. La trazabilidad convierte el modelo en una arquitectura verificable. Sin trazabilidad, el modelo parece una construcción arbitraria. Con trazabilidad, cada decisión puede explicarse. En este sentido, el producto final no es solo una figura con flechas ni una tabla de resultados, sino una argumentación completa que conecta problema, teoría, método y evidencia. **El modelo estructural evaluado debe poder narrarse, justificarse y defenderse como contribución de investigación** (Colquitt & George, 2011).

Por último, este tema 7.1 cierra la ruta formativa del libro al destacar que investigar con SEM/PLS-SEM exige pensamiento estructural antes que destreza

instrumental. La destreza en software es necesaria, pero insuficiente. Un investigador puede saber usar SmartPLS, ADANCO, WarpPLS, R o cualquier otro programa, y aun así construir un modelo débil si no domina la lógica conceptual. La competencia central consiste en formular problemas modelables, construir preguntas estructurales, diferenciar constructos, justificar relaciones, especificar medición, interpretar resultados y reportar con transparencia. Por eso, el aprendizaje de SEM/PLS-SEM no debe reducirse a seguir pasos técnicos, sino a desarrollar criterio investigador. Este criterio permite saber cuándo una relación tiene sentido, cuándo un constructo está mal definido, cuándo un indicador no corresponde, cuándo un modelo está sobrecargado, cuándo una predicción es insuficiente y cuándo una conclusión excede los datos. **El verdadero dominio de SEM/PLS-SEM no consiste en ejecutar un modelo, sino en construirlo, evaluarlo, interpretarlo y defenderlo científicamente** (Guenther et al., 2023).

Construcción del modelo SEM como producto científico

La construcción del modelo SEM como producto científico implica comprender que el modelo no es únicamente un diagrama con flechas, ni una representación gráfica generada por software, sino una síntesis argumentativa de todo el proceso de investigación. Un modelo estructural científicamente defendible condensa una idea inicial, un fenómeno delimitado, un problema investigable, una pregunta estructural, un sistema conceptual, un marco relacional, constructos definidos, indicadores operacionalizados, hipótesis formuladas y criterios de evaluación empírica. Por ello, el modelo no debe aparecer de manera repentina en el capítulo metodológico o en la sección de resultados; debe ser el resultado visible de una cadena de decisiones previas. Cuando un lector observa un modelo SEM/PLS-SEM, debería poder reconocer qué fenómeno se está estudiando, qué variable resultado organiza la explicación, qué antecedentes fueron seleccionados, qué mecanismos se proponen, qué condiciones podrían modificar las relaciones y qué tipo de evidencia se usará para evaluar el sistema. En este sentido, **el modelo SEM es un producto científico porque traduce teoría en una arquitectura evaluable**, no porque simplemente permita calcular coeficientes. Su valor no radica en la estética del diagrama, sino en la trazabilidad entre problema, teoría, medición, hipótesis y análisis empírico. Un modelo sin trazabilidad puede ser técnicamente estimable, pero científicamente débil; en cambio, un modelo construido como producto científico permite explicar por qué cada constructo existe, por qué cada flecha fue incorporada y qué aporta el conjunto a la comprensión del fenómeno (Whetten, 1989).

El modelo SEM se convierte en producto científico cuando responde a un vacío de conocimiento y no solo a una posibilidad estadística. En ciencias de la administración, es frecuente que el investigador identifique variables ampliamente utilizadas —liderazgo, innovación, satisfacción, desempeño, aprendizaje, confianza, capacidades digitales— y las combine en un diagrama sin demostrar con claridad qué vacío atiende. Sin embargo, un modelo científico no se justifica por el atractivo de sus

constructos, sino por su capacidad para responder una tensión específica de la literatura o de la práctica. El vacío puede ser teórico, cuando una relación no ha sido explicada suficientemente; empírico, cuando existe poca evidencia en cierto contexto; metodológico, cuando la medición o el enfoque analítico requieren mejora; o práctico, cuando un problema organizacional necesita una explicación útil. Desde esta perspectiva, el modelo debe presentarse como una respuesta organizada a ese vacío. Si el vacío señala que no se comprende cómo las capacidades digitales se traducen en desempeño innovador, entonces el modelo debe explicar qué antecedentes, mediadores o moderadores permiten comprender esa relación. Si el vacío indica que falta evidencia predictiva sobre adopción tecnológica, el modelo debe orientarse a predicción y no únicamente a significancia estadística. **El modelo es producto científico cuando su estructura responde directamente al vacío que justificó la investigación** (Gregor, 2006). De esta forma, es posible:

Construir el modelo como producto científico demanda definir con claridad la variable dependiente o constructo resultado. Esta variable representa aquello que el estudio desea explicar, predecir o comprender dentro de una arquitectura estructural. Puede tratarse de desempeño innovador, intención de uso, satisfacción, aprendizaje organizacional, sostenibilidad, competitividad, adopción tecnológica, resiliencia organizacional o cualquier otro resultado relevante para la investigación. Sin una variable dependiente clara, el modelo pierde dirección y puede convertirse en una red dispersa de constructos. La variable dependiente cumple una función organizadora: permite seleccionar antecedentes, justificar mecanismos, delimitar moderadores y establecer criterios de interpretación. Por ejemplo, si el resultado central es desempeño innovador, los antecedentes deben tener una relación teórica con la innovación; si el resultado es intención de uso, los predictores deben explicar por qué un sujeto aceptaría o rechazaría una tecnología. Esta decisión también afecta la revisión de literatura, la formulación de hipótesis, la elección de indicadores y el tipo de análisis. Por ello, **la variable dependiente no es solo una variable más; es el eje de sentido del modelo**. Un modelo científicamente sólido debe mostrar que todas las relaciones contribuyen, directa o indirectamente, a comprender el resultado central (Hair et al., 2021).

Seleccionar variables explicativas con fundamento teórico y no por acumulación bibliográfica. Un modelo SEM no mejora por incluir muchas variables; mejora cuando cada variable cumple una función clara dentro de la explicación del fenómeno. En investigación aplicada, es común que el investigador agregue constructos porque aparecen en estudios previos, porque son recientes o porque parecen conceptualmente atractivos. Esta práctica puede producir modelos extensos, pero no necesariamente rigurosos. Las variables explicativas deben seleccionarse porque ayudan a responder la pregunta de investigación y porque tienen una relación defendible con la variable resultado. Cada antecedente debe responder una pregunta básica: ¿por qué este constructo debería influir en el resultado central? Si la respuesta no es clara, la variable probablemente no pertenece al modelo. Esta lógica evita el coleccionismo de constructos y fortalece la parsimonia. Además, permite distinguir entre antecedentes principales, variables de control, mediadores y moderadores. **La**

calidad del modelo depende menos del número de predictores y más de la coherencia de su función teórica. Un modelo con pocos constructos bien articulados puede aportar más que un modelo saturado de relaciones débiles, redundantes o difíciles de interpretar (Corley & Gioia, 2011).

Distinguir si el modelo busca explicar, predecir o combinar ambas finalidades. Esta decisión no es menor, porque afecta la forma de construir, evaluar e interpretar el modelo. Un modelo explicativo busca comprender por qué ocurre una relación, qué mecanismos la sostienen y cómo se conecta con la teoría. Un modelo predictivo busca anticipar valores de una variable resultado con la mayor precisión posible. En muchos estudios PLS-SEM se afirma que el modelo es causal-predictivo, pero después solo se reportan coeficientes, significancia y R^2 , sin evaluar capacidad predictiva fuera de muestra. Esa práctica debilita la coherencia metodológica. Si el modelo se presenta como explicativo, debe fundamentarse en teoría, hipótesis y mecanismos. Si se presenta como predictivo, debe incluir criterios como Q^2 , PLSpredict, RMSE, MAE o Q^2 _predict. Si combina explicación y predicción, debe reportar ambos planos con claridad. **Un modelo científico debe ser coherente con su propósito analítico**: no puede prometer predicción si no evalúa predicción, ni puede afirmar explicación teórica si solo presenta ajuste estadístico. Esta distinción permite evitar confusiones entre apoyo empírico, varianza explicada y utilidad predictiva (Shmueli, 2010).

Construir el modelo como producto científico es formular hipótesis estructurales que deriven de la teoría y no únicamente de correlaciones esperadas. Una hipótesis no debe ser una frase decorativa colocada antes del análisis; debe expresar una relación precisa entre constructos, con dirección esperada y fundamento conceptual. Por ejemplo, no basta con decir que “las capacidades digitales se relacionan con la innovación”; una hipótesis más sólida indicaría que “las capacidades digitales influyen positiva y significativamente en el desempeño innovador”, siempre que esa relación se derive de literatura y razonamiento teórico. Las hipótesis permiten transformar el marco relacional en proposiciones evaluables. Cada hipótesis debe corresponder a una ruta del modelo, y cada ruta debe poder rastrearse hasta el problema y la teoría. Esta trazabilidad es esencial para que el modelo sea defendible. Si una hipótesis no responde a la pregunta de investigación, debe revisarse; si una flecha no se convierte en hipótesis, debe justificarse como relación de control o eliminarse; si una hipótesis carece de fundamento, puede generar resultados estadísticos sin valor científico. **Las hipótesis son el puente entre la teoría y la evaluación empírica del modelo** (Gefen et al., 2000).

Definir con precisión los constructos antes de seleccionar indicadores o escalas. En SEM/PLS-SEM, muchos fenómenos relevantes no son observables directamente: confianza, compromiso, satisfacción, capacidad innovadora, cultura organizacional, aprendizaje, autoeficacia o sostenibilidad. Por ello, el investigador debe construir definiciones conceptuales claras que indiquen qué incluye y qué excluye cada constructo. Sin esa definición, los indicadores pueden volverse ambiguos, redundantes o desconectados del dominio conceptual. Un constructo no es una lista de ítems; es una entidad teórica que se representa mediante indicadores. Por ejemplo,

si se define “capacidad digital”, debe aclararse si se refiere a infraestructura tecnológica, habilidades humanas, procesos digitales, cultura organizacional, estrategia de datos o una combinación de estos elementos. Cada decisión tiene consecuencias. Un constructo mal definido puede producir problemas de validez convergente, validez discriminante o interpretación estructural. **La calidad del modelo científico inicia en la calidad de las definiciones conceptuales**. Los índices estadísticos pueden advertir problemas, pero no sustituyen la necesidad de delimitar correctamente el constructo desde el inicio (Churchill, 1979).

Especificar correctamente la relación entre constructos e indicadores, distinguiendo modelos reflectivos, formativos y compuestos. En un modelo reflectivo, el constructo causa sus indicadores; si cambia el constructo, se espera que cambien sus manifestaciones. En un modelo formativo, los indicadores forman el constructo; cada indicador aporta una parte del significado. En un modelo compuesto, los indicadores se combinan como componentes de una entidad construida analíticamente. Esta decisión no debe tomarse por conveniencia del software, sino por la teoría del constructo. Si el investigador trata como reflectivo un constructo que en realidad es formativo, puede exigir correlaciones internas inadecuadas; si trata como formativo un constructo reflectivo, puede ignorar consistencia interna necesaria. Esta especificación afecta cargas, pesos, confiabilidad, colinealidad, validez y sentido de la interpretación. Por tanto, **el modelo científico exige congruencia entre teoría de medición y técnica de análisis**. En PLS-SEM, esta distinción es especialmente relevante porque el método permite trabajar con constructos reflectivos, formativos y compuestos, pero esa flexibilidad exige mayor responsabilidad conceptual. La pregunta central debe ser: ¿los indicadores reflejan el constructo, lo forman o lo componen? (Jarvis et al., 2003).

Asegurar que el modelo de medición sostenga la interpretación del modelo estructural. No se puede interpretar con rigor una relación entre constructos si los constructos no están adecuadamente medidos. Por ello, antes de discutir hipótesis, coeficientes o efectos, el investigador debe revisar la calidad de la medición. En modelos reflectivos, esto implica evaluar cargas externas, confiabilidad interna, confiabilidad compuesta, rho_A, AVE y validez discriminante. En modelos formativos o compuestos, se debe analizar colinealidad, relevancia de pesos, cargas, validez de contenido y contribución de cada indicador. Esta evaluación no debe entenderse como un filtro mecánico de umbrales; debe interpretarse desde la teoría y el dominio conceptual del constructo. Por ejemplo, eliminar un indicador solo porque su carga es menor puede ser incorrecto si ese indicador representa una dimensión central del concepto. Del mismo modo, conservar indicadores redundantes puede inflar artificialmente la confiabilidad. El modelo de medición **constituye una base empírica central** del modelo científico, porque conecta los conceptos con los datos. Si la medición falla, la estructura puede parecer estadísticamente significativa, pero teóricamente será frágil (Fornell & Larcker, 1981).

Construir un modelo estructural parsimonioso, interpretable y alineado con el problema de investigación. El modelo estructural representa las relaciones entre

constructos, pero no debe confundirse con un mapa exhaustivo de todas las relaciones posibles. Su función es organizar aquellas rutas que son necesarias para responder la pregunta central. En este sentido, la parsimonia es una virtud metodológica. Un modelo parsimonioso no es un modelo pobre, sino un modelo que evita complejidad innecesaria. Cada flecha debe tener fundamento; cada constructo debe cumplir una función; cada hipótesis debe aportar a la explicación o predicción del resultado. Un modelo saturado puede generar problemas de interpretación, colinealidad, bajo poder estadístico y sobreajuste. En cambio, un modelo bien delimitado permite comunicar con claridad qué se propone, qué se evalúa y qué se concluye. La parsimonia **contribuye a fortalecer** el carácter científico del modelo porque obliga a justificar cada decisión estructural. En investigación SEM/PLS-SEM, el modelo debe ser suficientemente amplio para representar el fenómeno, pero suficientemente claro para ser defendido, estimado, interpretado y replicado (Hair et al., 2019).

Considerar mediaciones y moderaciones solo cuando aportan valor teórico. Los modelos estructurales pueden enriquecerse mediante mediadores y moderadores, pero estas relaciones no deben incorporarse solo para aumentar sofisticación. La mediación explica cómo o por qué ocurre una relación; la moderación explica cuándo, para quién o bajo qué condiciones una relación cambia. Por ejemplo, el aprendizaje organizacional puede mediar la relación entre capacidades digitales y desempeño innovador si se sostiene que las capacidades digitales generan aprendizaje y este aprendizaje se traduce en innovación. La turbulencia ambiental puede moderar esa relación si se argumenta que las capacidades digitales son más relevantes en contextos cambiantes. Sin embargo, si el mediador o moderador no tiene fundamento conceptual, su inclusión debilita el modelo. **La complejidad relacional solo tiene valor científico cuando mejora la explicación del fenómeno**. Un modelo directo puede ser más sólido que un modelo mediado o moderado si la teoría no justifica mecanismos o condiciones adicionales. Por ello, el investigador debe agregar relaciones complejas por necesidad explicativa, no por ornamentación estadística (Nitzl et al., 2016).

Reconocer que el modelo científico debe ser evaluable, replicable y comunicable. Un modelo evaluable tiene constructos definidos, indicadores claros, hipótesis precisas y criterios de análisis adecuados. Un modelo replicable proporciona información suficiente para que otros investigadores comprendan cómo fue construido y, eventualmente, lo apliquen en otros contextos. Un modelo comunicable puede explicarse sin depender exclusivamente del lenguaje técnico del software. Estas tres cualidades son esenciales para convertir el modelo en producto científico. Si el lector no puede identificar qué significa cada constructo, por qué se incluyó cada relación o cómo se evaluaron los resultados, el modelo pierde transparencia. Por ello, el investigador debe cuidar la presentación visual, la descripción metodológica, la tabla de constructos, la matriz de hipótesis y la narración de resultados. **Un modelo científico no solo debe estimarse correctamente; debe poder explicarse con claridad**. Esta exigencia es especialmente importante en tesis, artículos y capítulos de libro, donde el modelo debe ser comprendido por lectores con distintos niveles de formación metodológica (Bem, 2004).

Evaluar la capacidad explicativa del modelo sin confundirla con relevancia absoluta. En PLS-SEM, el R^2 permite conocer cuánta varianza de un constructo endógeno es explicada por sus predictores. Este indicador es útil porque informa la fuerza explicativa interna del modelo. Sin embargo, un R^2 alto no significa automáticamente que el modelo sea teóricamente superior, ni que tenga buena capacidad predictiva fuera de la muestra. También debe considerarse el f^2 para valorar la contribución individual de cada predictor, así como el sentido teórico de las relaciones. Un predictor puede ser significativo pero aportar poco; otro puede tener un efecto moderado y ser sustantivamente relevante. Por ello, **la explicación del modelo debe interpretarse en conjunto con teoría, magnitud, contexto y propósito del estudio**. Un modelo científico no se defiende solo con indicadores altos, sino con una lectura equilibrada de sus resultados. La capacidad explicativa es una dimensión importante, pero debe integrarse con medición, hipótesis, predicción, comparación y discusión teórica (Hair et al., 2021).

Evaluar la capacidad predictiva cuando el modelo declara orientación predictiva o causal-predictiva. Esta evaluación es particularmente relevante en PLS-SEM, porque el método suele utilizarse para explicar y predecir constructos objetivo. Sin embargo, la predicción no debe inferirse únicamente a partir de R^2 . Un modelo puede explicar bien la muestra analizada y, aun así, fallar al anticipar nuevos casos. Por ello, procedimientos como PLSpredict permiten evaluar errores de predicción mediante RMSE, MAE y Q^2 _predict. Esta evaluación permite saber si el modelo tiene utilidad más allá de los datos usados para estimarlo. En campos como administración, innovación, educación y marketing, esta dimensión es importante porque muchos modelos pretenden orientar decisiones. Si el modelo predice intención de uso, desempeño o satisfacción, debe demostrar capacidad para anticipar esos resultados con error razonable. **La predicción convierte el modelo en una herramienta potencialmente útil para la práctica, pero exige evidencia específica**. Un modelo científico no debe prometer poder predictivo si no lo evalúa con criterios adecuados (Shmueli et al., 2019).

Comparar modelos cuando existan alternativas teóricamente defendibles. El modelo propuesto por el investigador no siempre es la única forma plausible de representar el fenómeno. Puede existir un modelo directo, uno mediado, uno moderado, uno jerárquico o uno más parsimonioso. Comparar modelos permite evaluar cuál configuración ofrece mejor equilibrio entre teoría, parsimonia, explicación y predicción. En PLS-SEM, criterios como BIC, GM, PLSpredict, RMSE, MAE o Q^2 _predict pueden apoyar esta comparación. No obstante, la comparación no debe convertirse en prueba y error. Las alternativas deben estar justificadas conceptualmente. Un modelo rival debe competir por explicar o predecir el mismo constructo objetivo y debe derivarse de una lógica teórica razonable. **La comparación de modelos fortalece el producto científico porque muestra que la arquitectura final fue evaluada frente a opciones plausibles**. Esta práctica aporta madurez metodológica y evita presentar el modelo propuesto como si fuera evidente o incuestionable (Dijkstra & Henseler, 2015).

Incorporar controles de calidad metodológica, como sesgo de método común, endogeneidad, colinealidad y suficiencia muestral. Un modelo puede tener relaciones significativas y aun así estar afectado por sesgos de diseño o estimación. El sesgo de método común puede surgir cuando todos los datos provienen de la misma fuente o instrumento; la endogeneidad puede aparecer por variables omitidas, causalidad inversa o simultaneidad; la colinealidad puede distorsionar la interpretación de predictores; y una muestra insuficiente puede reducir estabilidad estadística. Estos aspectos no deben tratarse como detalles secundarios, porque afectan la credibilidad del modelo. Un producto científico debe mostrar que el investigador reconoce y controla, en la medida de lo posible, amenazas a la validez del análisis. **La solidez del modelo depende tanto de sus resultados como de la calidad del diseño que los produjo**. Por ello, el reporte debe incluir decisiones sobre muestra, potencia, control de sesgos, justificación del método y límites de inferencia (Podsakoff et al., 2024).

Conectar los resultados con contribuciones teóricas, metodológicas y prácticas. Un modelo SEM/PLS-SEM no debe terminar en una tabla de hipótesis apoyadas; debe explicar qué aportan esos hallazgos. La contribución teórica puede consistir en confirmar, ampliar, refinar o cuestionar relaciones previas. La contribución metodológica puede estar en la forma de medir un constructo, comparar modelos, evaluar predicción o especificar relaciones complejas. La contribución práctica puede orientar decisiones en empresas, instituciones, mercados o políticas organizacionales. Esta conexión es esencial para convertir el modelo en producto de investigación. Si el modelo no responde al vacío inicial, la contribución será débil. Por ello, la discusión debe volver al problema de investigación y mostrar cómo los resultados ayudan a resolverlo. **El modelo adquiere valor científico cuando sus resultados producen conocimiento comunicable y útil para una comunidad académica o profesional**. La contribución no se improvisa al final; se construye desde la forma en que se planteó el problema y se diseñó el modelo (Colquitt & George, 2011).

Finalmente, la construcción del modelo SEM como producto científico exige una actitud de prudencia interpretativa. Los modelos estructurales permiten evaluar relaciones teóricamente justificadas, pero no convierten automáticamente datos transversales en evidencia causal definitiva. El investigador debe ser cuidadoso al hablar de influencia, efecto o causalidad, especialmente cuando no cuenta con diseño longitudinal, experimental o controles robustos. También debe reconocer límites de generalización, calidad de muestra, tipo de instrumento, contexto y posibles sesgos. Esta prudencia no reduce el valor del modelo; al contrario, lo fortalece, porque muestra madurez científica. Un producto de investigación serio no exagera sus conclusiones ni oculta sus restricciones. **El modelo SEM es una representación analítica del fenómeno, no el fenómeno mismo**. Por ello, debe presentarse como una arquitectura empíricamente evaluada, conceptualmente defendible y abierta a futuras validaciones. La calidad científica se expresa tanto en lo que el investigador afirma como en los límites que reconoce (Guenther et al., 2023).

Apartado metodológico para tesis, artículo o capítulo de libro

La redacción del apartado metodológico constituye una fase decisiva para convertir el modelo SEM/PLS-SEM en un producto académico verificable, replicable y evaluable. No basta con haber construido un modelo conceptualmente sólido, definido constructos, diseñado indicadores, recolectado datos y ejecutado un software especializado; todo ese proceso debe ser narrado de manera clara para que el lector comprenda qué se hizo, por qué se hizo y bajo qué criterios se tomaron las decisiones metodológicas. En una tesis, un artículo científico o un capítulo de libro, la metodología no debe presentarse como una sección administrativa, sino como el espacio donde se demuestra la coherencia entre problema, objetivo, diseño, muestra, instrumento, técnica de análisis y criterios de evaluación. En SEM/PLS-SEM, esta exigencia es todavía más importante porque el análisis estructural integra teoría, medición y relaciones entre constructos. Por ello, el apartado metodológico debe explicar la lógica completa del estudio: cuál fue el enfoque, qué tipo de diseño se utilizó, quiénes participaron, cómo se midieron los constructos, cómo se evaluó el modelo de medición, cómo se examinó el modelo estructural y por qué se eligió PLS-SEM u otro enfoque relacionado. **Una metodología bien redactada no solo describe procedimientos; justifica decisiones científicas**. Esto permite que el lector valore la consistencia del estudio y que otros investigadores puedan replicar, cuestionar o extender el modelo en nuevos contextos(Hair et al., 2019).

Redacción del enfoque general de investigación. En estudios con SEM/PLS-SEM, normalmente se trabaja desde un enfoque cuantitativo, porque se analizan relaciones entre variables, constructos e indicadores mediante datos numéricos. Sin embargo, no basta con escribir que el estudio es “cuantitativo”; debe explicarse qué significa eso para la investigación. Un enfoque cuantitativo implica que el fenómeno se operacionaliza mediante variables observables, que los constructos se miden mediante escalas o indicadores, que las relaciones se expresan en hipótesis evaluables y que el análisis busca estimar parámetros, efectos, capacidad explicativa o poder predictivo. Si el estudio utiliza datos de encuesta, debe indicarse que los constructos fueron captados a partir de percepciones, actitudes, comportamientos declarados o evaluaciones realizadas por los participantes. Si se usan datos secundarios, debe explicarse la fuente, el periodo y la forma en que cada variable representa el fenómeno. **El enfoque metodológico debe conectar directamente con el propósito del estudio**: explicar relaciones, predecir resultados, validar medición, comparar grupos o evaluar un modelo estructural. En una tesis, esta explicación puede ser más amplia; en un artículo, debe ser más sintética; en un capítulo de libro, puede integrarse de manera narrativa, pero siempre con claridad. La idea central es que el lector entienda que el enfoque no se eligió por rutina, sino porque corresponde al tipo de pregunta estructural formulada. (Gefen et al., 2000).

Diseño de investigación, que debe indicar si el estudio es transversal, longitudinal, explicativo, predictivo, correlacional, confirmatorio o causal-

predictivo. En muchos estudios SEM/PLS-SEM se utiliza un diseño transversal, porque los datos se recolectan en un solo momento. Esto debe declararse con precisión, ya que afecta el alcance de las inferencias. Un diseño transversal puede evaluar relaciones estructurales teóricamente justificadas, pero no permite sostener causalidad fuerte con la misma solidez que un diseño longitudinal o experimental. Por eso, en la redacción metodológica conviene usar términos prudentes como “relaciones estructurales”, “efectos estimados”, “influencias teóricamente esperadas” o “asociaciones explicativas”, en lugar de afirmar causalidad definitiva. Si el estudio tiene orientación predictiva, debe indicarse que el modelo busca valorar la capacidad de anticipar un constructo endógeno, no solo contrastar hipótesis. Si el estudio es confirmatorio, debe señalarse que las relaciones fueron derivadas de teoría previa. **El diseño metodológico delimita lo que el modelo puede afirmar y lo que no debe exagerar**. Esta precisión fortalece la credibilidad del trabajo, especialmente ante revisores, comités de tesis o lectores especializados. Una metodología sólida no promete más de lo que el diseño permite sostener. (Shmueli, 2010).

Descripción de la población, la unidad de análisis y la muestra. Este apartado debe responder con claridad quiénes o qué fueron estudiados. La población representa el conjunto amplio al que se refiere el estudio; la unidad de análisis indica el nivel en el que se interpretan los datos; y la muestra corresponde al subconjunto efectivamente observado. En ciencias de la administración, la unidad de análisis puede ser el individuo, el equipo, la empresa, la institución, el proyecto, la región o la red organizacional. Esta decisión es fundamental porque los indicadores deben corresponder al mismo nivel. Si el modelo estudia capacidades organizacionales, pero los datos provienen de empleados individuales, debe justificarse si los participantes responden como informantes de la organización o si el constructo se interpreta como percepción individual. En la metodología debe indicarse el tamaño de muestra, el procedimiento de selección, los criterios de inclusión y exclusión, el contexto geográfico o institucional, el sector, el perfil de los participantes y cualquier característica relevante para interpretar los resultados. **La muestra no debe describirse solo como número; debe presentarse como base empírica del modelo**. Además, cuando se utiliza PLS-SEM, conviene justificar la suficiencia muestral con criterios apropiados, evitando depender únicamente de reglas simples o desactualizadas. (Kock & Hadaya, 2018).

La justificación del tamaño de muestra es especialmente importante en investigaciones SEM/PLS-SEM. Durante años se utilizó la regla de diez veces el mayor número de relaciones dirigidas hacia un constructo o indicadores de un bloque; sin embargo, esta regla debe considerarse solo como orientación mínima y no como justificación suficiente. Una metodología rigurosa puede apoyarse en criterios de potencia estadística, en el número de predictores del constructo endógeno principal, en el tamaño esperado del efecto, en el nivel de significancia y en la potencia deseada. Si el estudio cuenta con una muestra amplia, debe explicarse que el tamaño es suficiente para estimar el modelo con estabilidad. Si la muestra es limitada, debe justificarse con prudencia y reconocer limitaciones. La redacción debe evitar frases vagas como “la muestra fue suficiente porque PLS-SEM acepta muestras pequeñas”.

Esa afirmación es metodológicamente débil. **PLS-SEM puede ser útil con muestras moderadas, pero no convierte automáticamente una muestra pequeña en adecuada**. Por ello, el apartado metodológico debe especificar por qué el número de observaciones permite estimar las relaciones propuestas. En tesis doctorales y artículos empíricos, esta justificación aporta rigor y reduce cuestionamientos sobre potencia estadística, estabilidad de parámetros y generalización de resultados. (Cohen, 1992).

Descripción del instrumento de medición. Si el estudio utiliza cuestionario, la metodología debe explicar cómo fue construido, qué escalas se emplearon, de qué fuentes se adaptaron los ítems, qué tipo de respuesta se utilizó y cómo se aseguró la correspondencia entre constructos e indicadores. No basta con decir que "se aplicó un cuestionario tipo Likert"; debe indicarse si la escala fue de cinco, siete u otro número de puntos, qué significaban los extremos de respuesta y por qué ese formato resultó pertinente. También debe señalarse si los ítems fueron adaptados de estudios previos, traducidos, contextualizados o redactados específicamente para el estudio. En modelos SEM, la calidad del instrumento es central porque los constructos latentes dependen de indicadores. **Un instrumento mal construido debilita toda la interpretación del modelo**, aunque posteriormente los coeficientes parezcan significativos. Por ello, conviene incluir una tabla metodológica con constructo, definición conceptual, número de ítems, ejemplo de indicador, fuente bibliográfica y tipo de medición. Esta tabla permite mostrar trazabilidad entre teoría, constructo e indicador. En artículos, puede presentarse de forma sintética; en tesis, con mayor detalle. (Churchill, 1979).

Explicar la operacionalización de los constructos. Este apartado debe indicar cómo cada concepto teórico fue convertido en una variable medible. La operacionalización requiere definir el constructo, delimitar su dominio conceptual, identificar dimensiones si existen, seleccionar indicadores y establecer la escala de medición. Por ejemplo, si el estudio mide "capacidad digital organizacional", debe explicar si esa capacidad incluye infraestructura tecnológica, habilidades del personal, procesos digitalizados, cultura digital o estrategia de datos. Si mide "desempeño innovador", debe precisar si se refiere a nuevos productos, mejora de procesos, resultados comerciales de innovación o percepción general de éxito innovador. Además, debe indicarse si cada constructo fue modelado como reflectivo, formativo o compuesto. **La operacionalización es el puente entre teoría y datos**, por lo que no debe redactarse como una lista de variables, sino como una justificación de cómo se hizo observable el fenómeno. En PLS-SEM, esta decisión es particularmente relevante porque el método permite trabajar con distintos tipos de modelos de medición, pero cada uno exige criterios de evaluación diferentes. La claridad de esta sección ayuda a evitar confusiones entre indicadores, dimensiones, antecedentes y consecuencias. (Jarvis et al., 2003).

Especificación del tipo de modelo de medición: reflectivo, formativo o compuesto. En un modelo reflectivo, los indicadores son manifestaciones del constructo; por ello, se espera que estén correlacionados y que reflejen una misma

variable subyacente. En un modelo formativo, los indicadores forman el constructo; cada indicador aporta una parte del significado y no necesariamente debe correlacionarse con los demás. En un modelo compuesto, los indicadores se combinan para representar una entidad construida analíticamente. Esta distinción debe aparecer en la metodología porque determina cómo se evaluará la calidad del modelo. Si se trata de constructos reflectivos, se reportarán cargas externas, confiabilidad, AVE y validez discriminante. Si se trata de constructos formativos, se revisará colinealidad, pesos, relevancia e importancia de indicadores. **El investigador debe justificar el tipo de medición con base en la teoría, no con base en el software**. Una mala especificación puede afectar la validez completa del estudio. Por ello, la metodología debe explicar por qué cada constructo fue tratado como reflectivo, formativo o compuesto, especialmente cuando el constructo es complejo, multidimensional o se usa como índice. (Diamantopoulos & Winklhofer, 2001).

Explicación del procedimiento de recolección de datos. El lector debe saber cómo se aplicó el instrumento, en qué periodo, mediante qué medio, con qué criterios éticos y bajo qué condiciones. Si se aplicó en línea, debe indicarse la plataforma o procedimiento general, la forma de invitación, el control de duplicados si existió y el manejo de respuestas incompletas. Si se aplicó presencialmente, debe explicarse el contexto de aplicación, la autorización institucional y las instrucciones dadas a los participantes. También conviene indicar si la participación fue voluntaria, si se garantizó anonimato o confidencialidad y si los datos fueron utilizados exclusivamente con fines académicos. **La recolección de datos no es un detalle operativo menor; afecta la calidad, confiabilidad y validez del estudio**. En estudios con cuestionario, debe tenerse especial cuidado con sesgos de respuesta, deseabilidad social, cansancio del participante, comprensión de ítems y representatividad de la muestra. Una redacción metodológica completa no necesita ser excesivamente larga, pero sí debe ser transparente. Esto permite valorar la calidad del trabajo empírico y anticipar posibles limitaciones del análisis. (Podsakoff et al., 2024).

Preparación y depuración de la base de datos. Antes de estimar un modelo SEM/PLS-SEM, el investigador debe revisar datos faltantes, respuestas inconsistentes, valores extremos, patrones de respuesta repetitivos, codificación de ítems, inversión de reactivos si aplica y adecuación del archivo para el software. Esta etapa suele omitirse en reportes breves, pero es importante porque una base mal depurada puede afectar los resultados. En la metodología debe indicarse cómo se trataron los casos incompletos, si se eliminaron observaciones, si se imputaron datos y bajo qué criterio. También debe señalarse si se revisó la distribución de las variables, aunque PLS-SEM no exige normalidad multivariada estricta como otros enfoques. **La preparación de datos es una fase de control de calidad previa al análisis**, no un trámite técnico. Si el investigador no reporta cómo organizó y revisó la base, el lector no puede valorar plenamente la confiabilidad del análisis posterior. En tesis, esta sección puede ser más detallada; en artículos, puede resumirse en un párrafo metodológico. En ambos casos, debe mostrar que el análisis se realizó sobre datos consistentes y adecuados. (Hair et al., 2021).

Justificación de la técnica SEM/PLS-SEM seleccionada. Esta sección debe explicar por qué se eligió PLS-SEM y no otra técnica. Una justificación sólida puede basarse en el propósito predictivo del estudio, la orientación causal-predictiva, la presencia de constructos formativos o compuestos, la complejidad del modelo, el desarrollo teórico en un área emergente o la necesidad de estimar puntuaciones de constructos. Lo que debe evitarse es justificar PLS-SEM únicamente con frases genéricas como "se usó porque permite muestras pequeñas" o "porque es más flexible". Esas afirmaciones son insuficientes. **La técnica debe elegirse por coherencia con el objetivo, la teoría, la medición y la estructura del modelo**. Si el estudio busca explicar y predecir un constructo objetivo mediante múltiples relaciones, PLS-SEM puede ser adecuado. Si el estudio solo desea confirmar una teoría muy consolidada con énfasis en ajuste global, quizá otra técnica sería más pertinente. Como el libro se orienta principalmente a PLS-SEM, la metodología debe enfatizar que la elección responde a la lógica del modelo y no a comodidad operativa. (Hair et al., 2019).

Indicar el software utilizado y su función dentro del análisis. El software no debe presentarse como sustituto del método, sino como herramienta para implementar la técnica elegida. Si se utiliza SmartPLS, ADANCO, WarpPLS, SEMinR, cSEM u otro programa, debe mencionarse la versión cuando sea posible, así como los procedimientos ejecutados: algoritmo PLS, *bootstrapping*, evaluación del modelo de medición, evaluación del modelo estructural, PLSpredict, análisis multigrupo o comparación de modelos. La redacción puede ser sencilla: "El análisis se realizó mediante PLS-SEM utilizando SmartPLS, debido a que el estudio buscó evaluar relaciones estructurales con orientación explicativa-predictiva y constructos medidos mediante indicadores reflectivos/formativos". **El software debe aparecer después de la justificación metodológica, no antes**. Esto evita la impresión de que el estudio fue diseñado alrededor de una herramienta. En investigación científica, primero se define el problema y el método; después se selecciona el programa que permite estimar el modelo. Esta precisión es útil para lectores que confunden PLS-SEM con SmartPLS o SEM con AMOS. (Henseler, 2017).

Explicar el procedimiento de evaluación del modelo de medición. La metodología debe anticipar qué criterios se usarán para decidir si los constructos están adecuadamente medidos. En modelos reflectivos, esto incluye cargas externas, confiabilidad interna, confiabilidad compuesta, AVE y validez discriminante. En modelos formativos, se deben indicar criterios como VIF, pesos externos, significancia de pesos y relevancia teórica de indicadores. No es necesario discutir resultados en la metodología, pero sí explicar los criterios que se aplicarán. Por ejemplo: "La evaluación del modelo de medición reflectivo consideró cargas externas, confiabilidad compuesta, AVE y HTMT para valorar validez discriminante". **El apartado metodológico debe preparar al lector para entender los resultados**. Si los criterios aparecen por primera vez en la sección de resultados, el reporte puede parecer improvisado. Al anunciarlos previamente, el investigador muestra que el análisis siguió una ruta planificada. Esta transparencia ayuda a distinguir una investigación rigurosa de una exploración posterior a los datos. (Fornell & Larcker, 1981).

Explicar el procedimiento de evaluación del modelo estructural. Esta parte debe indicar cómo se valorarán las relaciones entre constructos. En PLS-SEM, normalmente se revisa colinealidad entre predictores, coeficientes de trayectoria, significancia mediante *bootstrapping*, R^2 , f^2 y Q^2 . También pueden incluirse mediación, moderación, análisis multigrupo, poder predictivo o comparación de modelos si corresponden al objetivo. En la metodología debe señalarse que los coeficientes se interpretarán de acuerdo con su signo, magnitud, significancia y coherencia teórica. También debe aclararse que R^2 se utilizará para valorar capacidad explicativa interna y que f^2 permitirá estimar contribuciones individuales de predictores. **La evaluación estructural no debe reducirse a probar hipótesis; debe valorar el comportamiento completo del sistema relacional**. Este apartado muestra que el investigador entiende la diferencia entre medir bien los constructos y evaluar las relaciones entre ellos. Además, permite anticipar cómo se reportarán hipótesis apoyadas, no apoyadas, efectos directos, efectos indirectos y efectos totales. (Chin, 1998).

Describir el uso de *bootstrapping* para contrastar hipótesis. En PLS-SEM, el *bootstrapping* se utiliza para obtener errores estándar, valores t, valores p e intervalos de confianza, especialmente porque permite evaluar la estabilidad de parámetros sin depender de supuestos estrictos de normalidad. La metodología debe indicar el número de submuestras de remuestreo utilizado cuando se conozca, así como el tipo de prueba y nivel de significancia. También debe explicarse que este procedimiento se aplicará para evaluar coeficientes de trayectoria y, cuando corresponda, efectos indirectos en mediación. **El *bootstrapping* no debe presentarse como un botón del software, sino como un procedimiento de inferencia estadística**. Su función es estimar la precisión y significancia de los parámetros del modelo. En reportes académicos, esta explicación fortalece la transparencia porque permite que el lector comprenda cómo se determinó si una hipótesis recibió apoyo empírico. También evita interpretar los coeficientes de manera aislada, sin considerar su estabilidad y precisión. (Hair et al., 2021).

Explicar el tratamiento de mediaciones, moderaciones o modelos avanzados cuando formen parte del estudio. Si el modelo incluye mediación, la metodología debe indicar que se evaluarán efectos indirectos y sus intervalos de confianza. Si incluye moderación, debe explicar cómo se construyó el término de interacción y cómo se interpretará. Si incluye análisis multigrupo, debe señalar si se revisó invariancia de medición antes de comparar grupos. Si incluye modelos jerárquicos, debe explicar el enfoque utilizado para estimar constructos de segundo orden. **Los análisis avanzados deben ser anunciados y justificados metodológicamente antes de presentar resultados**. No deben aparecer de manera sorpresiva como recursos adicionales. Por ejemplo, si se plantea que el aprendizaje organizacional media la relación entre capacidades digitales y desempeño innovador, la metodología debe indicar que se evaluará el efecto indirecto mediante *bootstrapping*. Esta claridad muestra coherencia entre hipótesis, análisis y reporte. Además, evita que los análisis complejos parezcan agregados post hoc para obtener resultados más atractivos. (Nitzl et al., 2016).

Describir la evaluación del poder predictivo cuando el estudio lo requiera. Si el modelo se presenta como predictivo o causal-predictivo, la metodología debe explicar qué criterios se utilizarán para evaluar predicción. No basta con reportar R^2, porque este indicador muestra varianza explicada dentro de la muestra, pero no necesariamente desempeño predictivo fuera de muestra. Por ello, conviene indicar si se utilizará Q^2, PLSpredict, RMSE, MAE o Q^2 _predict. También debe explicarse que los errores predictivos se interpretarán comparándolos con modelos de referencia cuando sea posible. **La predicción debe declararse y evaluarse metodológicamente, no solo afirmarse en la discusión**. En estudios aplicados, esta sección es muy valiosa porque permite mostrar si el modelo tiene utilidad para anticipar resultados como intención de uso, desempeño, satisfacción o innovación. Una metodología completa distingue entre explicar relaciones y predecir valores. Esa distinción eleva la calidad del estudio y evita conclusiones exageradas sobre la utilidad del modelo. (Shmueli et al., 2019).

Explicar la comparación de modelos cuando esta forme parte del diseño analítico. Si el estudio compara un modelo directo con uno mediado, un modelo simple con uno moderado o un modelo de primer orden con uno jerárquico, debe indicarlo en la metodología. La comparación debe estar justificada por teoría y no por prueba y error. Además, debe señalarse qué criterios se usarán para decidir cuál modelo es preferible: BIC, AIC, GM, RMSE, MAE, Q^2 _predict, R^2 o criterios de ajuste, según el enfoque. **Comparar modelos exige transparencia desde la metodología**, porque el lector debe saber si las alternativas fueron previstas o si surgieron después del análisis. Si la comparación es exploratoria, debe declararse como tal. En PLS-SEM, la comparación puede fortalecer la argumentación cuando existen modelos rivales conceptualmente defendibles. Sin embargo, no debe convertirse en búsqueda oportunista del “mejor número”. Su función es evaluar qué arquitectura ofrece mejor equilibrio entre teoría, parsimonia, explicación y predicción. (Dijkstra & Henseler, 2015).

Atención a sesgos y amenazas de validez. En investigaciones basadas en cuestionarios, especialmente cuando la información proviene de una sola fuente, puede existir sesgo de método común. En estudios transversales, puede haber limitaciones para interpretar causalidad. En modelos complejos, puede aparecer colinealidad. En modelos con variables omitidas, puede existir endogeneidad. La metodología no necesita resolver todos estos problemas de manera definitiva, pero sí debe reconocerlos y, cuando sea posible, describir acciones preventivas o diagnósticas. Por ejemplo, se puede mencionar anonimato, separación psicológica de constructos, revisión de colinealidad, control de variables relevantes o discusión de límites del diseño. **Un apartado metodológico robusto no solo describe lo que se hizo, también muestra conciencia de los riesgos del diseño**. Esto incrementa la credibilidad del estudio porque evidencia que el investigador no interpreta los resultados de manera ingenua. En tesis y artículos, reconocer estas amenazas suele ser mejor que omitirlas, ya que permite una interpretación más prudente y defendible. (Hult et al., 2018).

Redactar la metodología con una secuencia clara y replicable. Una estructura recomendable incluye: enfoque y diseño del estudio; población, unidad de análisis y muestra; instrumento y operacionalización de constructos; procedimiento de recolección de datos; preparación de la base; técnica de análisis, algoritmo de estimación y software empleado; criterios de evaluación del modelo de medición; criterios de evaluación del modelo estructural; análisis complementarios, como mediación, moderación, predicción o comparación de modelos; y consideraciones éticas o limitaciones metodológicas. En estudios PLS-SEM, esta secuencia debe permitir reportar con trazabilidad la especificación del modelo estructural, la especificación del modelo de medición, la recolección y examen de datos, la estimación del modelo PLS o PLSc, la confiabilidad, la validez convergente, la validez discriminante, la colinealidad, los coeficientes *path*, R^2 , f^2 y, cuando el objetivo lo requiera, PLSpredict o CVPAT. La metodología debe narrarse como una ruta de decisiones conectadas, no como una acumulación de apartados desconectados. En artículos, el espacio puede obligar a sintetizar; en tesis, se puede ampliar cada sección. En capítulos de libro, puede adoptarse un tono más explicativo. Pero en todos los casos debe conservarse coherencia, precisión y trazabilidad. Una metodología bien ordenada anticipa un reporte de resultados más claro y reduce la posibilidad de críticas por falta de información (Bem, 2004).

Una redacción metodológica adecuada también debe diferenciar entre tesis, artículo y capítulo de libro. En una tesis, se espera mayor detalle: justificación del diseño, descripción completa del instrumento, tabla de operacionalización, criterios de muestra, procedimiento de aplicación, pruebas preliminares y explicación de cada criterio SEM/PLS-SEM. En un artículo científico, la metodología debe ser más compacta, pero suficiente para evaluación por pares; debe incluir lo esencial sin convertir la sección en manual técnico. En un capítulo de libro empírico, puede equilibrarse explicación y síntesis, dependiendo del público. **El nivel de detalle cambia según el producto académico, pero la lógica metodológica debe permanecer constante**. En todos los formatos, el lector debe poder responder: qué se hizo, con quién, cómo se midió, por qué se eligió la técnica, cómo se evaluó el modelo y qué criterios guiaron la interpretación. La diferencia no está en la rigurosidad, sino en el grado de extensión permitido. Una tesis puede justificar ampliamente; un artículo debe concentrar; un capítulo puede contextualizar y enseñar. (Colquitt & George, 2011).

Finalmente, el apartado metodológico debe escribirse con precisión, sobriedad y trazabilidad académica. La redacción debe evitar afirmaciones exageradas, tecnicismos innecesarios o frases genéricas que no aporten evidencia. Expresiones como “se utilizó PLS-SEM por ser una técnica moderna” o “el cuestionario fue validado porque tuvo buen alfa” son insuficientes. En cambio, conviene escribir de manera específica: “Se utilizó PLS-SEM debido a la orientación predictiva del estudio, la presencia de constructos compuestos y la necesidad de evaluar la varianza explicada de los constructos endógenos”. También debe evitarse presentar resultados en la metodología; esta sección debe explicar procedimientos, no adelantar hallazgos. **La metodología es el contrato de transparencia entre el investigador y el lector**:

establece los criterios con los que se construyó, midió, estimó y evaluó el modelo. Si está bien redactada, el lector podrá comprender y valorar los resultados con mayor confianza. Por ello, en SEM/PLS-SEM, escribir la metodología no es un cierre administrativo, sino una parte sustantiva de la calidad científica del producto de investigación. (Guenther et al., 2023).

Presentación e interpretación de resultados SEM/PLS-SEM

La presentación e interpretación de resultados SEM/PLS-SEM constituye el momento en que el modelo deja de ser una arquitectura estimada y se convierte en evidencia académica comunicable. Después de construir el problema, formular la pregunta estructural, definir constructos, operacionalizar indicadores, justificar la técnica y evaluar el modelo, el investigador debe explicar qué significan los resultados obtenidos. Esta fase no debe reducirse a copiar tablas del software ni a declarar de forma mecánica si las hipótesis fueron “aceptadas” o “rechazadas”. En un producto de investigación serio, la presentación de resultados debe mostrar una secuencia lógica: primero, la calidad del modelo de medición; después, la evaluación del modelo estructural; posteriormente, el contraste de hipótesis; y, cuando corresponda, la interpretación de efectos directos, indirectos, totales, moderaciones, poder predictivo y comparación de modelos. **Interpretar resultados significa conectar números con teoría, problema, contexto y contribución científica**. Por ello, el investigador debe evitar dos extremos: presentar solo estadísticas sin explicación o interpretar excesivamente resultados débiles. Un buen reporte SEM/PLS-SEM combina claridad técnica y lectura sustantiva: muestra los indicadores necesarios, pero también explica qué revelan sobre el fenómeno estudiado. La bibliografía metodológica base del capítulo respalda esta lógica de reporte e interpretación de modelos estructurales. (Hair et al., 2019).

La primera regla para presentar resultados SEM/PLS-SEM es seguir el orden natural del análisis: modelo de medición antes que modelo estructural. Esta secuencia es indispensable porque no tiene sentido interpretar relaciones entre constructos si antes no se demuestra que los constructos fueron medidos de manera válida y confiable. En modelos reflectivos, el reporte debe incluir cargas externas, confiabilidad interna, confiabilidad compuesta, varianza media extraída y validez discriminante. En modelos formativos o compuestos, deben presentarse criterios como colinealidad, pesos, cargas, relevancia teórica e importancia de cada indicador. La lógica es clara: antes de decir que X influye en Y, debe mostrarse que X y Y están adecuadamente representados por sus indicadores. Si el modelo de medición es débil, la interpretación estructural será frágil. Por ello, el investigador debe redactar esta sección con prudencia, explicando no solo si se cumplieron criterios, sino qué implican. Por ejemplo, no basta con afirmar que “las cargas fueron aceptables”; conviene indicar que los indicadores muestran correspondencia empírica con sus constructos y que la medición ofrece base suficiente para interpretar las relaciones posteriores. **La medición es la base de la interpretación estructural**. (Fornell & Larcker, 1981).

La presentación del modelo de medición debe evitar el reporte mecánico de umbrales. En muchos trabajos se escriben frases como “el alfa fue mayor a .70, el AVE mayor a .50 y el HTMT menor a .90; por tanto, el modelo es válido”. Aunque esos criterios son útiles, una redacción académicamente sólida debe explicar su sentido. Las cargas externas muestran la relación entre indicador y constructo; la confiabilidad informa la consistencia interna; el AVE evalúa la proporción de varianza explicada por el constructo sobre sus indicadores; y la validez discriminante permite verificar que los constructos sean empíricamente distintos. El investigador debe interpretar esos resultados como evidencia acumulativa, no como casillas aisladas. Además, cuando algún indicador se encuentra cerca del límite, debe explicarse si se conserva por razones teóricas o si se elimina por debilidad empírica. **Los criterios estadísticos orientan la decisión, pero la teoría del constructo debe guiar la interpretación final**. Esta postura evita eliminar indicadores relevantes solo por criterios automáticos o conservar indicadores débiles sin justificación conceptual. La presentación de resultados debe mostrar que el investigador entiende el significado de cada índice y no solo reproduce reglas generales. (Henseler et al., 2015).

Cuando el modelo incluye constructos formativos o compuestos, la presentación de resultados requiere un tratamiento distinto al de los constructos reflectivos. En estos casos no se espera necesariamente que los indicadores estén altamente correlacionados, porque cada indicador puede representar una parte diferente del constructo. Por ejemplo, una capacidad digital organizacional puede estar compuesta por infraestructura tecnológica, habilidades del personal, procesos digitalizados y cultura digital. Cada componente aporta información distinta y no debe evaluarse con la misma lógica de una escala reflectiva tradicional. Por ello, el reporte debe incluir colinealidad entre indicadores, pesos externos, cargas y relevancia conceptual. Si un peso no resulta significativo, el indicador no debe eliminarse automáticamente; puede conservarse si su carga es relevante o si representa una dimensión esencial del dominio conceptual. **En modelos formativos o compuestos, la interpretación debe centrarse en la contribución de cada indicador al significado del constructo**. Este punto es clave para evitar errores frecuentes de especificación y reporte. La presentación de resultados debe dejar claro que el investigador comprende la naturaleza del modelo de medición y que no aplica criterios reflectivos a constructos que no corresponden a esa lógica. (Diamantopoulos & Winklhofer, 2001).

Después de presentar el modelo de medición, el investigador debe reportar el modelo estructural de manera ordenada. Esta sección debe mostrar cómo se comportan las relaciones entre constructos. En PLS-SEM, normalmente se reportan colinealidad entre predictores, coeficientes de trayectoria, valores t, valores p, intervalos de confianza, R^2 , f^2 y Q^2 . La interpretación no debe limitarse a decir si una ruta es significativa. El coeficiente debe leerse según su signo, magnitud, dirección esperada y relación con la teoría. Por ejemplo, un coeficiente positivo entre capacidades digitales y desempeño innovador debe interpretarse como evidencia de que, en la muestra estudiada, mayores capacidades digitales se asocian con mayor desempeño innovador, siempre dentro de los límites del diseño. Si el coeficiente es

bajo, aunque significativo, debe evitarse exagerar su relevancia. Si el coeficiente no es significativo, se debe explicar qué podría implicar: ausencia de relación en ese contexto, medición inadecuada, mediación no considerada, moderación no explorada o insuficiente variabilidad empírica. **El modelo estructural debe interpretarse como sistema de relaciones, no como lista de coeficientes aislados**. (Hair et al., 2021).

La interpretación de hipótesis debe ser clara, prudente y coherente con la teoría. Una hipótesis apoyada no debe presentarse como "verdad comprobada", sino como una relación que recibió apoyo empírico en una muestra, contexto, diseño e instrumento determinados. Del mismo modo, una hipótesis no apoyada no debe tratarse como fracaso automático. En investigación científica, los resultados no apoyados pueden ser valiosos porque muestran límites de la teoría, diferencias contextuales, relaciones indirectas no previstas o problemas de medición. La redacción debe evitar expresiones absolutas como "se comprobó definitivamente" o "se demostró causalmente", especialmente cuando se trabaja con diseños transversales. Es más adecuado escribir: "los resultados ofrecen apoyo empírico para la relación propuesta" o "la hipótesis no recibió apoyo estadístico suficiente en la muestra analizada". **El contraste de hipótesis es una evaluación situada, no una sentencia universal**. Además, cada hipótesis debe vincularse con el marco conceptual: si fue apoyada, se explica cómo fortalece la teoría; si no fue apoyada, se discuten posibles razones y nuevas rutas de investigación. Esta forma de reporte muestra madurez metodológica e interpretativa. (Gefen et al., 2000).

La presentación de resultados debe distinguir entre significancia estadística y relevancia sustantiva. Un coeficiente puede ser estadísticamente significativo y, aun así, tener baja magnitud o poca importancia práctica. Esto ocurre especialmente en muestras grandes, donde efectos pequeños pueden alcanzar significancia. Por ello, el investigador debe complementar valores p con tamaños del efecto, intervalos de confianza, R^2 y razonamiento teórico. En PLS-SEM, f^2 permite valorar la contribución individual de un predictor sobre un constructo endógeno. Un predictor puede tener un coeficiente significativo, pero un f^2 pequeño, lo que sugiere que su contribución específica es limitada. Esta distinción evita exagerar resultados por el simple hecho de que una ruta sea significativa. **La relevancia científica de un resultado depende de su magnitud, coherencia teórica y utilidad interpretativa, no solo de su significancia estadística**. En la redacción, conviene explicar cuáles efectos son centrales, cuáles son secundarios y cuáles deben interpretarse con cautela. Esto ayuda a construir una discusión más equilibrada y evita convertir la sección de resultados en una celebración indiscriminada de todas las rutas significativas. (Cohen, 1992).

El R^2 debe presentarse como indicador de capacidad explicativa interna, no como prueba absoluta de calidad del modelo. Este índice muestra la proporción de varianza explicada de un constructo endógeno por sus predictores. Por ejemplo, un R^2 de .52 indica que el modelo explica 52% de la varianza del resultado analizado dentro de la muestra. Sin embargo, el investigador debe evitar decir que el modelo "explica todo" o que "predice" solo por tener R^2 aceptable. El R^2 debe interpretarse según el

campo, el tipo de fenómeno, la complejidad del modelo y la naturaleza de los datos. En ciencias sociales, valores moderados pueden ser relevantes cuando el fenómeno es complejo y depende de múltiples factores. Además, un R^2 alto puede estar asociado con redundancia conceptual o sobreajuste si se agregaron demasiados predictores. **El R^2 informa cuánto explica el modelo dentro de la muestra, pero no sustituye la evaluación teórica, predictiva ni de parsimonia**. Por ello, debe reportarse junto con otros criterios como f^2, Q^2, PLSpredict y discusión sustantiva de los resultados. (Hair et al., 2019).

La interpretación de efectos indirectos y mediación exige especial cuidado porque no se trata solo de reportar una ruta adicional. La mediación permite explicar el mecanismo mediante el cual un antecedente influye en un resultado. Por ejemplo, si las capacidades digitales influyen en el desempeño innovador mediante aprendizaje organizacional, el mediador ayuda a comprender cómo esas capacidades se traducen en resultados. En la presentación de resultados, el investigador debe reportar el efecto indirecto, su significancia mediante *bootstrapping* y su intervalo de confianza. Sin embargo, también debe explicar el sentido teórico del mecanismo. No basta con afirmar que "la mediación fue significativa"; debe indicarse qué revela ese hallazgo sobre el fenómeno. Además, debe distinguirse si la mediación es parcial o total, y si el efecto directo permanece significativo al incluir el mediador. **La mediación aporta valor cuando convierte una relación estadística en una explicación del proceso subyacente**. Por ello, debe estar alineada con el marco teórico y no aparecer como un resultado exploratorio sin fundamento. (Nitzl et al., 2016).

La interpretación de moderaciones también debe ir más allá del término de interacción. Una moderación indica que la relación entre dos constructos cambia según el nivel de una tercera variable. Por ejemplo, la relación entre capacidades digitales y desempeño innovador puede ser más fuerte en entornos con alta turbulencia ambiental. En los resultados, el investigador debe reportar el coeficiente de interacción, su significancia y, de ser posible, una representación gráfica de la interacción. Sin embargo, lo más importante es explicar qué significa la moderación. Una interacción significativa implica que la relación principal no es homogénea en todos los casos. Esto puede tener valor teórico y práctico porque muestra que ciertas condiciones fortalecen o debilitan el efecto. **La moderación responde al cuándo, para quién o bajo qué condiciones ocurre una relación**. Si no se explica esta lógica, el reporte queda incompleto. Además, una moderación no significativa también debe interpretarse: puede sugerir que la relación es estable en la muestra o que la variable moderadora no opera como se esperaba. (Hair et al., 2021).

Cuando el estudio incluye evaluación predictiva, los resultados deben distinguir claramente entre explicación y predicción. Un modelo puede tener hipótesis apoyadas y R^2 aceptable, pero no necesariamente predecir bien nuevos casos. Por ello, si se utiliza PLSpredict, se deben reportar métricas como RMSE, MAE y Q^2 _predict, además de comparar el desempeño del modelo con un modelo de referencia cuando sea posible. La interpretación debe indicar si el modelo presenta poder predictivo bajo, medio o alto, según el patrón de errores predictivos. No basta

con escribir que "Q^2 _predict fue positivo"; conviene explicar si los errores del modelo son menores que los de alternativas simples. **La predicción se demuestra mediante reducción de error, no mediante significancia de rutas**. Esta distinción es especialmente importante en estudios aplicados, donde se afirma que el modelo puede orientar decisiones sobre adopción tecnológica, desempeño, satisfacción o innovación. Una presentación rigurosa debe reconocer si el poder predictivo es sólido, parcial o limitado. (Shmueli et al., 2019).

La comparación de modelos debe presentarse cuando existan alternativas teóricamente defendibles. El investigador puede comparar un modelo directo con uno mediado, un modelo simple con uno moderado, un modelo con dimensiones separadas frente a un modelo jerárquico, o un modelo propuesto frente a un modelo rival. En la sección de resultados, deben presentarse los criterios utilizados para comparar las alternativas, como BIC, AIC, GM, RMSE, MAE, Q^2 _predict o índices de ajuste, según el enfoque. Sin embargo, la comparación no debe ser un ejercicio oportunista de búsqueda del mejor número. Debe explicarse por qué cada modelo alternativo fue considerado y qué representa teóricamente. **El modelo preferible no es necesariamente el más complejo, sino el que ofrece mejor equilibrio entre teoría, parsimonia, explicación y predicción**. La redacción debe mostrar por qué se conserva una arquitectura y no otra. Esto fortalece la defensa del modelo final y demuestra que el investigador evaluó alternativas razonables antes de interpretar sus hallazgos. (Dijkstra & Henseler, 2015).

La presentación de resultados debe incorporar tablas, figuras y texto interpretativo de manera equilibrada. Las tablas permiten organizar indicadores de medición, coeficientes, hipótesis, efectos y criterios predictivos. Las figuras ayudan a visualizar el modelo estructural, los coeficientes de trayectoria o las interacciones. Sin embargo, ni las tablas ni las figuras sustituyen la interpretación. Cada tabla debe tener un propósito claro y cada figura debe aportar comprensión. Un error frecuente es saturar el documento con tablas extensas tomadas del software, sin explicar qué significan. Otro error es escribir conclusiones sin mostrar la evidencia suficiente. **La función de las tablas es documentar; la función del texto es interpretar**. Por ello, el reporte debe combinar ambos planos: presentar evidencia suficiente y explicar su significado. En una tesis puede haber más detalle; en un artículo debe haber mayor síntesis; en un capítulo de libro puede privilegiarse la claridad pedagógica. En todos los casos, la presentación debe ser ordenada y verificable. (Bem, 2004).

La interpretación de resultados debe regresar siempre al problema de investigación. Después de presentar cargas, coeficientes, R^2 , efectos indirectos o poder predictivo, el investigador debe responder: ¿qué revelan estos resultados sobre el problema inicial? Si el estudio partió de un vacío sobre cómo las capacidades digitales se relacionan con desempeño innovador, la interpretación debe explicar si esa relación fue apoyada, qué tan fuerte fue, si operó mediante mediadores, si dependió de moderadores y qué implicaciones tiene para el contexto estudiado. Un reporte débil se queda en el nivel técnico; un reporte fuerte vuelve al problema y muestra cómo los resultados lo esclarecen. **Los resultados tienen valor científico**

cuando responden la pregunta que originó el modelo. Esta conexión evita que el análisis parezca una colección de indicadores sin dirección. Además, permite construir la discusión posterior, donde se comparan los hallazgos con la literatura previa y se formulan contribuciones teóricas, metodológicas o prácticas. (Gregor, 2006).

Los resultados no apoyados deben interpretarse con la misma seriedad que los apoyados. En muchos trabajos, las hipótesis no significativas se minimizan o se presentan como errores. Sin embargo, una hipótesis no apoyada puede ser informativa. Puede revelar que una teoría no opera igual en determinado contexto, que existe una variable mediadora omitida, que la relación depende de una condición no considerada, que los constructos fueron medidos de manera insuficiente o que el fenómeno tiene una lógica distinta. Por ello, el investigador debe evitar borrar, ocultar o justificar de manera superficial los resultados no favorables. **Un resultado no apoyado puede generar conocimiento si se interpreta con rigor**. En la redacción, conviene señalar posibles explicaciones, pero sin especular excesivamente. También puede proponerse que futuras investigaciones exploren otros contextos, diseños longitudinales, moderadores o medidas alternativas. Esta actitud fortalece la credibilidad del estudio porque muestra transparencia y madurez científica. (Guenther et al., 2023).

La interpretación debe cuidar la prudencia causal, especialmente cuando el diseño es transversal y basado en encuestas. Aunque SEM/PLS-SEM permite evaluar relaciones estructurales teóricamente dirigidas, eso no significa que el investigador pueda afirmar causalidad definitiva sin considerar el diseño. En muchos estudios de administración, los datos se recolectan en un solo momento y provienen de percepciones de los participantes. En esos casos, es mejor hablar de relaciones estructurales, efectos estimados, asociaciones explicativas o influencia teóricamente esperada. Expresiones como “X causa Y” deben reservarse para diseños con mayor control causal, como estudios longitudinales, experimentales o cuasiexperimentales. **La prudencia causal no debilita el estudio; lo hace metodológicamente más honesto**. Además, cuando se reportan resultados, deben reconocerse posibles sesgos de método común, endogeneidad, variables omitidas o límites de generalización. Un reporte responsable evita convertir coeficientes en afirmaciones más fuertes de lo que permiten los datos. (Shmueli, 2010).

La presentación de resultados también debe reconocer amenazas de validez y sesgos metodológicos. Si los datos provienen de una sola fuente, existe riesgo de sesgo de método común. Si las variables se miden en el mismo momento, puede haber limitaciones para inferir direccionalidad temporal. Si faltan variables relevantes, puede existir endogeneidad. Si los predictores son muy similares, puede aparecer colinealidad. En el reporte, el investigador debe indicar qué diagnósticos se realizaron o qué medidas preventivas se tomaron. Por ejemplo, puede mencionarse revisión de VIF, análisis de colinealidad completa, estrategias de anonimato, separación de secciones en el cuestionario, revisión de patrones de respuesta o discusión de limitaciones. **Un resultado es más creíble cuando el investigador reconoce las condiciones bajo las cuales fue producido**. No se trata de debilitar el estudio, sino

de mostrar transparencia. Los revisores suelen valorar más un reporte prudente y consciente de sus límites que uno que presenta resultados como si no existieran amenazas metodológicas. (Podsakoff et al., 2024).

Una buena interpretación debe traducir los resultados en contribuciones teóricas, metodológicas y prácticas. La contribución teórica se refiere a cómo los hallazgos confirman, amplían, refinan o cuestionan relaciones previas. La contribución metodológica puede estar en la forma de medir un constructo, evaluar predicción, comparar modelos o incorporar mediaciones y moderaciones. La contribución práctica se relaciona con la utilidad de los hallazgos para organizaciones, instituciones, directivos, docentes, usuarios o tomadores de decisiones. Por ejemplo, si el modelo muestra que la autoeficacia digital predice intención de uso de IA, la implicación práctica puede ser diseñar programas de capacitación que fortalezcan habilidades percibidas. Si el aprendizaje organizacional media la relación entre capacidades digitales e innovación, la implicación puede ser que invertir en tecnología no basta si no se promueven rutinas de aprendizaje. **Los resultados se vuelven valiosos cuando se convierten en conocimiento accionable y teóricamente significativo**. Esta conexión debe prepararse desde la sección de resultados para sostener una discusión sólida. (Corley & Gioia, 2011).

El cierre de la presentación de resultados debe ofrecer una síntesis integradora del modelo evaluado. Después de reportar medición, estructura, hipótesis, efectos, predicción y comparación, el investigador debe explicar qué se aprendió del modelo en conjunto. Esta síntesis puede señalar cuáles constructos resultaron más relevantes, qué relaciones fueron centrales, qué mecanismos fueron apoyados, qué capacidad explicativa y predictiva mostró el modelo y qué límites deben considerarse. No debe repetirse toda la tabla de resultados, sino ofrecer una lectura global. Por ejemplo: “En conjunto, los hallazgos muestran que el desempeño innovador se explica principalmente por capacidades digitales y aprendizaje organizacional, y que el aprendizaje funciona como mecanismo central de transmisión; sin embargo, la capacidad predictiva del modelo fue moderada, por lo que se requieren validaciones adicionales”. **La síntesis integradora permite pasar de resultados fragmentados a una conclusión estructural del modelo**. Esta forma de cierre prepara la discusión, las conclusiones y las futuras líneas de investigación. (Hair et al., 2021).

En síntesis, la presentación e interpretación de resultados SEM/PLS-SEM debe entenderse como una práctica de argumentación científica. El investigador debe mostrar evidencia suficiente, pero también explicar su significado. Debe presentar el modelo de medición antes del estructural, interpretar hipótesis con prudencia, distinguir significancia de relevancia, analizar efectos directos e indirectos, valorar capacidad explicativa, evaluar poder predictivo cuando corresponda, comparar modelos si existen alternativas y regresar siempre al problema de investigación. Además, debe reconocer límites, evitar afirmaciones causales excesivas y traducir resultados en contribuciones. **Un reporte SEM/PLS-SEM de calidad no es el que presenta más tablas, sino el que permite comprender de manera clara, verificable y teóricamente fundada qué revela el modelo sobre el fenómeno estudiado**. En

ese sentido, el resultado final no es solo un conjunto de indicadores, sino una interpretación estructural capaz de sostener una tesis, un artículo o un capítulo de investigación. (Hair et al., 2019).

Discusión, contribuciones, limitaciones y futuras líneas de investigación

La discusión constituye el momento en que los resultados SEM/PLS-SEM dejan de ser únicamente evidencia estadística y se convierten en conocimiento académico argumentado. Después de presentar el modelo de medición, el modelo estructural, el contraste de hipótesis, los efectos directos e indirectos, la capacidad explicativa, el poder predictivo y, en su caso, la comparación de modelos, el investigador debe regresar al problema de investigación y responder qué significan los hallazgos. Esta sección no debe repetir mecánicamente los resultados, sino interpretarlos a la luz de la teoría, el contexto y los vacíos identificados al inicio del estudio. En una tesis, artículo o capítulo de libro, la discusión debe mostrar si el modelo propuesto confirma, amplía, cuestiona o matiza el conocimiento existente. También debe explicar por qué algunas relaciones fueron apoyadas y por qué otras no recibieron respaldo empírico. **La discusión no es una extensión de la sección de resultados; es una interpretación razonada de lo que los resultados aportan al conocimiento.** Por ello, debe articular tres niveles: el nivel empírico, que muestra qué se encontró; el nivel teórico, que explica cómo esos hallazgos dialogan con la literatura; y el nivel práctico, que señala qué implicaciones pueden derivarse para organizaciones, instituciones, investigadores o tomadores de decisiones. En estudios SEM/PLS-SEM, esta articulación es fundamental porque el modelo solo adquiere valor científico cuando sus coeficientes, efectos e índices se conectan con una explicación sustantiva del fenómeno. La bibliografía metodológica de base permite sostener esta lógica de interpretación, reporte y contribución académica. (Hair et al., 2019).

Una discusión sólida debe iniciar recuperando el objetivo general y la pregunta de investigación, porque ambos elementos funcionan como criterios de ordenamiento de los hallazgos. Si el estudio buscaba explicar el desempeño innovador a partir de capacidades digitales y aprendizaje organizacional, la discusión debe concentrarse en si esas relaciones fueron apoyadas y qué revelan sobre el fenómeno. Si el propósito era predecir intención de uso de una tecnología, la discusión debe valorar no solo las hipótesis apoyadas, sino también el desempeño predictivo del modelo. Si el objetivo era comparar modelos alternativos, la discusión debe explicar por qué una arquitectura estructural fue preferible frente a otra. **La discusión debe responder al estudio que se planteó, no a todos los temas que podrían derivarse de los resultados.** Este principio ayuda a evitar textos dispersos, donde el investigador comenta cada coeficiente de forma aislada, sin una narrativa integradora. La discusión debe organizarse alrededor de la lógica del modelo: qué variable dependiente se estudió, qué antecedentes resultaron relevantes, qué mecanismos fueron apoyados, qué condiciones no operaron como se esperaba y qué capacidad explicativa o predictiva mostró la arquitectura estructural. En este sentido, el

investigador debe evitar dos errores: repetir tablas sin interpretación o formular conclusiones generales que no están sostenidas por los resultados. La discusión debe ser selectiva, argumentativa y coherente con la pregunta estructural. (Gefen et al., 2000).

Interpretar las hipótesis apoyadas. Cuando una relación recibe apoyo empírico, el investigador debe explicar qué significa ese hallazgo para la teoría y para el fenómeno estudiado. No basta con decir que "la hipótesis fue aceptada" o que "la relación fue significativa". Es necesario analizar si el signo fue el esperado, si la magnitud del coeficiente fue relevante, si el tamaño del efecto aporta valor sustantivo y si la relación confirma lo planteado por estudios previos. Por ejemplo, si las capacidades digitales influyen positivamente en el desempeño innovador, la discusión debe explicar por qué este resultado fortalece la idea de que los recursos digitales no solo representan infraestructura tecnológica, sino condiciones para generar innovación. Si la autoeficacia predice intención de uso, debe señalarse que las creencias de capacidad personal pueden ser centrales para adoptar tecnología. **Una hipótesis apoyada tiene valor académico cuando se interpreta como evidencia dentro de una conversación teórica, no como una simple marca positiva en una tabla.** También debe evitarse exagerar los hallazgos: una relación significativa en una muestra específica no prueba una verdad universal. La discusión debe reconocer el contexto, el diseño y los límites inferenciales del estudio. (Hair et al., 2021).

Interpretae las hipótesis no apoyadas con el mismo rigor que las apoyadas. Una hipótesis no apoyada no debe presentarse como fracaso automático ni ocultarse en la narrativa. Puede revelar que una relación esperada no opera en el contexto estudiado, que el efecto depende de condiciones no consideradas, que existe un mecanismo mediador omitido, que los constructos fueron medidos de manera insuficiente o que la teoría requiere ajustes. Por ejemplo, si la relación directa entre capacidades digitales y desempeño innovador no resulta significativa, pero sí aparece un efecto indirecto mediante aprendizaje organizacional, la discusión puede señalar que la digitalización no se traduce automáticamente en innovación, sino que requiere procesos de aprendizaje para generar resultados. Si una moderación no es significativa, puede interpretarse que la relación principal es estable en la muestra o que la variable moderadora elegida no representa adecuadamente la condición contextual esperada. **Los resultados no apoyados pueden producir conocimiento cuando se explican con prudencia, teoría y sentido metodológico.** Esta lectura evita convertir la discusión en una defensa forzada del modelo. En investigación científica, las relaciones no confirmadas son oportunidades para refinar teoría, mejorar medición y proponer futuras investigaciones. (Guenther et al., 2023).

Explicar los efectos directos, indirectos y totales como parte de una arquitectura relacional. En modelos SEM/PLS-SEM, muchas relaciones no son lineales en sentido simple, sino que operan mediante mecanismos. Por ello, cuando el modelo incluye mediación, la discusión debe explicar cómo el mediador ayuda a comprender el fenómeno. Un efecto directo muestra que un constructo se relaciona con otro sin pasar por una variable intermedia; un efecto indirecto muestra que la

relación se transmite mediante un mecanismo; y el efecto total permite valorar la influencia global de una variable. Por ejemplo, si el liderazgo transformacional influye en la innovación a través del aprendizaje organizacional, la discusión debe resaltar que el liderazgo no solo actúa como antecedente directo, sino como detonador de procesos de aprendizaje que posteriormente favorecen la innovación. **La mediación aporta valor cuando permite explicar el proceso mediante el cual ocurre una relación.** En consecuencia, la discusión debe evitar frases superficiales como "existió mediación", y en su lugar explicar qué mecanismo fue respaldado, qué implica para la teoría y qué sugiere para la práctica. Esta interpretación es especialmente importante en ciencias de la administración, donde los fenómenos organizacionales suelen depender de procesos intermedios. (Nitzl et al., 2016).

Distinguir entre capacidad explicativa y poder predictivo. Un modelo puede explicar una proporción importante de varianza de un constructo endógeno mediante R^2 , pero eso no significa automáticamente que prediga bien casos nuevos. Si el estudio declara orientación predictiva, la discusión debe incorporar los resultados de PLSpredict, RMSE, MAE o Q^2 _predict, y explicar qué tan útil es el modelo para anticipar el constructo objetivo. Por ejemplo, un modelo puede explicar adecuadamente la intención de uso dentro de una muestra, pero mostrar errores predictivos altos frente a un modelo de referencia. En ese caso, la discusión debe reconocer que el modelo tiene valor explicativo, pero capacidad predictiva limitada. A la inversa, un modelo puede mostrar buena predicción, aunque su explicación teórica requiera fortalecimiento. **Explicar y predecir son finalidades distintas, por lo que la discusión debe tratarlas como dimensiones complementarias, no equivalentes.** Esta precisión mejora la calidad metodológica del trabajo, especialmente en PLS-SEM, donde muchas investigaciones justifican el método por su orientación predictiva, pero no siempre interpretan adecuadamente la predicción. (Shmueli et al., 2019).

Derivar contribuciones teóricas. Una contribución teórica no consiste en afirmar que "se aplicó un modelo" o que "se confirmaron relaciones", sino en explicar qué añade el estudio al conocimiento existente. La contribución puede consistir en confirmar una relación en un contexto poco estudiado, mostrar que un mecanismo mediador explica mejor una relación directa, evidenciar que un moderador no opera como se esperaba, distinguir constructos que suelen confundirse o proponer una arquitectura relacional más parsimoniosa. En ciencias de la administración, la contribución teórica debe responder a la pregunta: ¿qué entendemos ahora mejor gracias al modelo? Por ejemplo, si el estudio muestra que la capacidad digital solo mejora el desempeño innovador cuando existe aprendizaje organizacional, la contribución no es simplemente que "la capacidad digital importa", sino que su efecto depende de la conversión del recurso tecnológico en aprendizaje. **La teoría se fortalece cuando el modelo permite explicar relaciones, mecanismos o condiciones con mayor precisión.** Una contribución teórica sólida debe vincularse con el vacío señalado al inicio del estudio; de lo contrario, la discusión puede parecer desconectada del planteamiento original. (Whetten, 1989).

Identificar contribuciones metodológicas. En estudios SEM/PLS-SEM, una contribución metodológica puede surgir de la forma en que se especifican constructos, se distingue entre medición reflectiva, formativa o compuesta, se evalúa validez discriminante, se incorpora predicción, se compara modelos o se atienden sesgos de método común. Por ejemplo, si el estudio propone medir una capacidad organizacional como constructo compuesto en lugar de tratarla como escala reflectiva, puede aportar claridad metodológica. Si además compara modelos directos y mediados mediante criterios de parsimonia y predicción, puede mostrar una forma más rigurosa de seleccionar una arquitectura estructural. **La contribución metodológica aparece cuando el estudio mejora la forma de construir, medir, evaluar o reportar un fenómeno.** No todos los trabajos tendrán una contribución metodológica fuerte, pero cuando existe, debe explicarse de manera precisa. Esta contribución no debe confundirse con el simple uso de un software. Utilizar SmartPLS, ADANCO, WarpPLS o R no constituye por sí mismo una aportación metodológica; la aportación está en cómo se justifica, especifica, evalúa e interpreta el modelo. (Henseler, 2017).

Derivar contribuciones prácticas. En ciencias de la administración, innovación, marketing, educación o gestión tecnológica, los modelos SEM/PLS-SEM suelen tener implicaciones para organizaciones, instituciones, directivos, docentes, usuarios o responsables de política. Sin embargo, una contribución práctica no debe ser una recomendación genérica. Debe derivarse directamente de los resultados. Por ejemplo, si la autoeficacia influye en la intención de uso de inteligencia artificial, una implicación práctica puede ser diseñar programas de capacitación que aumenten la percepción de competencia de los usuarios. Si el aprendizaje organizacional media la relación entre capacidades digitales y desempeño innovador, la implicación puede ser que invertir en tecnología no basta: las organizaciones deben crear rutinas de aprendizaje, transferencia de conocimiento y experimentación. **Las implicaciones prácticas deben traducir los hallazgos en decisiones posibles, sin prometer efectos que el diseño no puede garantizar.** Esta prudencia es importante porque un modelo transversal basado en encuestas puede orientar decisiones, pero no debe presentarse como prueba definitiva de intervención causal. La utilidad práctica debe ser clara, proporcional y coherente con la evidencia. (Corley & Gioia, 2011).

Articular los resultados con la literatura previa. Una discusión sólida no se limita a decir si los hallazgos coinciden o no coinciden con estudios anteriores; debe explicar por qué podrían coincidir o diferir. Si una relación esperada se confirma, puede señalarse que el estudio extiende evidencia previa a un nuevo contexto, población o configuración de variables. Si una relación no se confirma, debe analizarse si el contexto, la medición, el diseño o la composición de la muestra podrían explicar la diferencia. Por ejemplo, una relación que aparece fuerte en grandes empresas puede ser débil en pymes por limitaciones de recursos; una variable que predice adopción tecnológica en usuarios expertos puede no hacerlo en usuarios principiantes; un constructo que funciona en economías desarrolladas puede operar distinto en economías emergentes. **La discusión debe convertir la comparación con la literatura en interpretación, no en una lista de coincidencias y discrepancias.** Esta práctica muestra que el investigador comprende el campo y no solo su propio

modelo. Además, permite ubicar el estudio dentro de una conversación académica más amplia. (Gregor, 2006).

Reconocer las limitaciones del estudio con precisión y sin debilitar innecesariamente el trabajo. Toda investigación tiene límites, pero no todos los límites tienen la misma importancia. En SEM/PLS-SEM, las limitaciones pueden relacionarse con diseño transversal, muestra no probabilística, uso de autoinforme, sesgo de método común, tamaño de muestra, medición perceptual, ausencia de variables de control, posible endogeneidad, falta de validación externa, contexto específico o restricciones en la capacidad predictiva. La redacción debe ser honesta, pero no autodestructiva. No conviene escribir que "los resultados no sirven" por tener limitaciones; debe explicarse qué alcance tienen. Por ejemplo, si los datos son transversales, se puede señalar que las relaciones se interpretan como asociaciones estructurales teóricamente orientadas, no como causalidad definitiva. Si la muestra pertenece a un contexto específico, se indica que la generalización debe ser cautelosa. **Reconocer limitaciones aumenta la credibilidad del estudio porque muestra conciencia metodológica.** Los revisores suelen valorar más una investigación que reconoce sus límites que una que presenta conclusiones absolutas. (Podsakoff et al., 2024).

Proponer futuras líneas de investigación derivadas de los hallazgos y limitaciones. Las futuras investigaciones no deben plantearse como una lista genérica, sino como rutas concretas para ampliar, contrastar o mejorar el modelo. Si el estudio fue transversal, una línea futura puede ser realizar diseños longitudinales para observar cambios en el tiempo. Si la muestra fue de un solo sector, puede proponerse comparar sectores o realizar análisis multigrupo. Si una hipótesis no fue apoyada, se pueden explorar mediadores o moderadores alternativos. Si el poder predictivo fue limitado, se pueden incorporar nuevos predictores o validar el modelo en muestras externas. Si hubo riesgo de sesgo de método común, se pueden utilizar fuentes múltiples de datos. **Las futuras líneas deben surgir de lo que el estudio encontró, no de posibilidades desconectadas.** Esta conexión muestra continuidad científica y permite que el modelo funcione como base para investigaciones posteriores. En PLS-SEM, también pueden proponerse futuras comparaciones de modelos, análisis de invariancia, PLSpredict en nuevas muestras o evaluación de endogeneidad. (Hult et al., 2018).

Cuidar el lenguaje causal, especialmente cuando el estudio utiliza datos transversales o perceptuales. Aunque el modelo SEM/PLS-SEM tenga flechas direccionales y coeficientes significativos, eso no significa que se pueda afirmar causalidad fuerte sin condiciones adicionales. La dirección de las relaciones debe estar respaldada por teoría, pero la evidencia empírica depende del diseño. Por ello, en la discusión conviene usar expresiones como "se asocia con", "presenta una relación positiva", "muestra un efecto estructural estimado", "recibe apoyo empírico" o "es consistente con la hipótesis planteada". Cuando se use la palabra "influye", debe hacerse con prudencia y vinculándola a la lógica teórica del modelo. **La prudencia causal protege la validez de la interpretación y evita conclusiones excesivas.**

Esta recomendación es especialmente relevante en ciencias de la administración, donde muchas investigaciones usan encuestas transversales para estudiar fenómenos complejos. Ser prudente no reduce el valor del estudio; al contrario, **evidencia dominio metodológico** y respeto por los límites de la evidencia (Shmueli, 2010).

En la discusión, los resultados deben organizarse por hallazgos principales y no necesariamente por el orden mecánico de las hipótesis. Si el modelo tiene muchas hipótesis, discutir una por una puede producir un texto fragmentado. Es preferible agrupar hallazgos en bloques interpretativos. Por ejemplo, un bloque puede abordar los antecedentes principales del resultado; otro, los mecanismos mediadores; otro, las condiciones moderadoras; otro, la capacidad predictiva; y otro, la comparación de modelos. Esta organización permite construir una narrativa más clara y evita repetir información. **La discusión debe contar la historia científica del modelo.** Esa historia debe responder qué se confirmó, qué no se confirmó, qué relación fue más importante, qué mecanismo explicó mejor el fenómeno, qué resultados fueron inesperados y qué aportan en conjunto. **Esta forma de redacción puede mejorar la calidad del producto académico porque permite que el lector comprenda el modelo como una totalidad, no como una suma de coeficientes.** En tesis, esta organización facilita la lectura del comité; en artículos, ayuda a comunicar una contribución más clara (Bem, 2004).

La discusión de resultados debe vincularse con la comparación de modelos cuando esta haya sido realizada. Si el estudio comparó un modelo directo con uno mediado, o un modelo simple con uno jerárquico, la discusión debe explicar qué significa que una alternativa haya sido preferible. Por ejemplo, si el modelo mediado obtuvo mejor desempeño que el modelo directo, la discusión puede señalar que el fenómeno no se explica adecuadamente mediante una relación simple, sino mediante un proceso intermedio. Si el modelo más parsimonioso tuvo desempeño similar al modelo complejo, se puede concluir que algunas variables adicionales no aportan suficiente valor. **La comparación de modelos permite fortalecer la discusión porque muestra que la arquitectura final fue evaluada frente a alternativas razonables.** Sin embargo, debe evitarse afirmar que el modelo seleccionado es universalmente superior. Solo puede decirse que fue preferible frente a las alternativas comparadas, en la muestra, contexto y criterios utilizados. Esta precisión mantiene la discusión en un nivel metodológicamente responsable. (Dijkstra & Henseler, 2015).

La discusión también debe señalar la relevancia de la medición para interpretar los hallazgos. Si el modelo de medición mostró buena confiabilidad, validez convergente y validez discriminante, la discusión puede sostener con mayor confianza que las relaciones estructurales se interpretan entre constructos adecuadamente representados. Si existieron indicadores débiles, cargas marginales o problemas de discriminación entre constructos, los hallazgos deben interpretarse con cautela. **No hay buena discusión estructural sin una lectura previa de la calidad de medición.** Por ejemplo, si dos constructos muy cercanos muestran problemas de validez discriminante, una relación significativa entre ellos puede reflejar traslape conceptual más que influencia sustantiva. Por ello, la discusión no debe tratar los

resultados estructurales como independientes del modelo de medición. La calidad de los constructos condiciona la fuerza de las conclusiones. Esta idea es particularmente importante cuando se trabaja con constructos complejos, formativos o compuestos, donde la validez de contenido y la especificación conceptual son decisivas. (Fornell & Larcker, 1981).

Las limitaciones deben redactarse de manera específica y conectarse con soluciones futuras. No basta con escribir "una limitación es el tamaño de muestra" o "se recomienda ampliar la muestra". Debe explicarse por qué ese límite importa y cómo podría atenderse. Por ejemplo, si el tamaño de muestra limita análisis multigrupo, la línea futura puede proponer una muestra mayor para comparar sectores, géneros, niveles educativos o tipos de empresa. Si el estudio usa datos de una sola fuente, la línea futura puede sugerir combinar encuestas con indicadores objetivos o evaluaciones de terceros. Si el diseño es transversal, se pueden proponer estudios longitudinales. **Una limitación bien redactada no solo reconoce una restricción; abre una ruta metodológica para mejorar el conocimiento.** Esta forma de escribir fortalece la parte final del capítulo, porque muestra que el investigador comprende cómo su estudio puede ampliarse. Además, evita limitaciones superficiales que no aportan nada al lector. (Kock & Hadaya, 2018).

Las contribuciones prácticas deben redactarse con un nivel adecuado de precisión. En lugar de afirmar de manera general que "los directivos deben mejorar la innovación", la discusión debe indicar qué factor del modelo resultó relevante y qué acción podría derivarse. Si el aprendizaje organizacional fue mediador, se puede recomendar fortalecer mecanismos de capacitación, intercambio de conocimiento y experimentación. Si la confianza fue predictor de intención de uso, se puede recomendar mejorar transparencia, seguridad percibida y comunicación institucional. Si la autoeficacia fue determinante, se puede sugerir entrenamiento gradual, acompañamiento y experiencias exitosas de uso. **La recomendación práctica debe salir del modelo, no de intuiciones externas.** Además, debe estar formulada de manera proporcional a la evidencia. Un estudio SEM puede orientar decisiones, pero no debe prometer que una intervención producirá automáticamente un resultado si no se probó experimentalmente. Esta prudencia mantiene la utilidad del estudio sin exagerar su alcance. (Colquitt & George, 2011).

El cierre de la discusión debe integrar contribuciones, límites y futuro en una conclusión argumentativa. Esta conclusión no debe repetir todo lo ya dicho, sino sintetizar qué aprendió el estudio sobre el fenómeno. Una buena fórmula consiste en señalar: primero, cuál fue el hallazgo central; segundo, qué aporta a la teoría; tercero, qué implica para la práctica; cuarto, qué límites deben considerarse; y quinto, qué línea futura resulta prioritaria. Por ejemplo: "Los resultados sugieren que las capacidades digitales no generan desempeño innovador de manera automática, sino a través del aprendizaje organizacional; este hallazgo contribuye a comprender el papel de los mecanismos internos en la innovación, orienta a las organizaciones a fortalecer rutinas de aprendizaje y requiere validación futura mediante diseños longitudinales y muestras sectoriales comparativas". **El cierre debe convertir los resultados en una**

afirmación científica prudente, clara y útil. Así, la discusión cumple su función principal: cerrar el ciclo entre problema, teoría, modelo, evidencia y futuras investigaciones. (Hair et al., 2021).

En síntesis, el tema muestra que la discusión, las contribuciones, las limitaciones y las futuras líneas de investigación no son secciones accesorias, sino el cierre científico del modelo SEM/PLS-SEM. La discusión interpreta los resultados; las contribuciones explican qué aporta el estudio; las limitaciones delimitan el alcance de las conclusiones; y las futuras líneas proyectan el conocimiento hacia nuevas investigaciones. Un producto académico de calidad no termina con hipótesis apoyadas ni con índices satisfactorios; termina cuando el investigador demuestra qué significan esos hallazgos, cómo dialogan con la literatura, qué decisiones pueden orientar, cuáles son sus límites y cómo pueden ampliarse. **La fuerza final de un modelo SEM/PLS-SEM depende de la coherencia entre la evidencia obtenida y la interpretación que se construye a partir de ella.** Por ello, la discusión debe ser rigurosa, prudente, teóricamente informada y metodológicamente transparente. Solo así el modelo deja de ser una estructura estadística para convertirse en una contribución académica defendible. (Hair et al., 2019).

Conclusiones

El Capítulo 7 permite concluir que **un modelo SEM/PLS-SEM no debe entenderse como una salida estadística aislada, sino como el resultado final de una cadena completa de decisiones científicas**. Desde la idea inicial hasta la discusión final, cada etapa cumple una función dentro del producto de investigación: la idea orienta el interés; el fenómeno delimita la realidad observable; el problema identifica el vacío; la pregunta estructura la relación central; el sistema conceptual organiza las variables; el marco relacional justifica las hipótesis; los constructos e indicadores hacen posible la medición; y la evaluación empírica permite contrastar, interpretar y reportar el modelo. Por ello, **la calidad del modelo depende de la coherencia acumulada entre formulación conceptual, medición, análisis e interpretación**, no solo de obtener coeficientes significativos o índices aceptables (Hair et al., 2019).

Una segunda conclusión es que **el modelo SEM adquiere valor científico cuando se construye como respuesta a un vacío de conocimiento**. No basta con reunir variables atractivas o reproducir modelos previos; el investigador debe demostrar qué tensión teórica, empírica, metodológica o práctica justifica la arquitectura propuesta. Cada constructo debe tener una función dentro del sistema, cada hipótesis debe derivarse de una relación teóricamente defendible y cada indicador debe representar adecuadamente el dominio conceptual del constructo. En este sentido, **el modelo estructural es una forma organizada de producir conocimiento**, porque traduce un problema de investigación en una arquitectura relacional susceptible de evaluación empírica (Whetten, 1989).

El capítulo también muestra que **la redacción metodológica es una condición de transparencia académica**. En tesis, artículos o capítulos de libro, la metodología debe

explicar con claridad el enfoque, diseño, población, muestra, unidad de análisis, instrumento, operacionalización de constructos, tipo de medición, técnica SEM/PLS-SEM, software y criterios de evaluación. Una metodología débil puede hacer que incluso un buen análisis pierda credibilidad, mientras que una metodología clara permite que el lector comprenda, evalúe y eventualmente replique el estudio. Por ello, **la metodología no es una descripción administrativa, sino la justificación ordenada de las decisiones que sostienen el modelo** (Bem, 2004).

Otra conclusión relevante es que **la presentación de resultados debe ir más allá de copiar tablas del software**. El investigador debe mostrar primero la calidad del modelo de medición, después la evaluación del modelo estructural, posteriormente el contraste de hipótesis y, cuando corresponda, la interpretación de mediaciones, moderaciones, poder predictivo y comparación de modelos. La presentación debe ser ordenada, verificable y sustantiva. Esto significa que los resultados deben conectarse con el problema de investigación y no presentarse como una acumulación de índices. **Interpretar resultados implica explicar qué revelan los coeficientes, efectos e indicadores sobre el fenómeno estudiado** (Hair et al., 2021).

Asimismo, el capítulo permite concluir que **la discusión convierte los resultados en contribución académica**. Una relación significativa solo tiene valor científico si se interpreta a la luz de la teoría, del contexto y del vacío identificado. Del mismo modo, una hipótesis no apoyada no debe ocultarse ni tratarse como fracaso, sino analizarse como evidencia que puede revelar límites teóricos, condiciones contextuales, problemas de medición o relaciones más complejas. La discusión debe articular contribuciones teóricas, metodológicas, empíricas y prácticas, siempre con prudencia interpretativa. **El producto de investigación alcanza madurez cuando explica qué aportan los hallazgos, qué límites tienen y qué nuevas preguntas abren** (Corley & Gioia, 2011).

Finalmente, el Capítulo 7 demuestra que **el cierre de una investigación SEM/PLS-SEM exige prudencia, trazabilidad y sentido crítico**. El investigador debe evitar afirmaciones causales excesivas cuando el diseño no las permite, reconocer limitaciones de muestra, medición, contexto, sesgo de método común, endogeneidad o generalización, y proponer futuras líneas de investigación conectadas con los hallazgos. Así, el modelo evaluado no se presenta como verdad definitiva, sino como una representación empíricamente sustentada, teóricamente defendible y abierta a nuevas validaciones. En consecuencia, **el verdadero dominio de SEM/PLS-SEM no consiste solo en ejecutar un modelo, sino en construirlo, justificarlo, evaluarlo, interpretarlo y comunicarlo como producto científico** (Guenther et al., 2023). Véase la **Tabla 7.1.**

Tabla 7.1 Del modelo SEM al producto de investigación

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Apartado metodológico	Sección donde se explica el enfoque, diseño, muestra, instrumento, técnica, software y criterios de evaluación del modelo.	Da transparencia al proceso de construcción, medición, estimación e interpretación del modelo SEM/PLS-SEM.	Debe explicar qué se hizo, por qué se hizo, cómo se hizo y bajo qué criterios se evaluó.	Bem (2004); Hair et al. (2019)
Arquitectura conceptual	Organización previa de idea, fenómeno, problema, pregunta, variables, constructos, indicadores e hipótesis.	Funciona como base lógica antes de estimar el modelo estructural.	Un modelo sólido debe derivarse de una arquitectura conceptual clara, no del software.	Whetten (1989); Gregor (2006)
Capacidad explicativa	Grado en que el modelo explica la varianza de los constructos endógenos.	Permite valorar qué tanto los predictores ayudan a comprender el resultado central.	Se interpreta principalmente mediante R^2 y se complementa con f^2 y sentido teórico.	Hair et al. (2019); Hair et al. (2021)
Capacidad predictiva	Capacidad del modelo para anticipar valores de constructos endógenos en casos nuevos o no usados directamente en la estimación.	Evalúa la utilidad práctica del modelo más allá de la explicación interna.	No debe inferirse solo por R^2; requiere Q^2, PLSpredict, RMSE, MAE o Q^2 _predict.	Shmueli et al. (2019)
Coherencia acumulada	Consistencia progresiva entre idea, fenómeno, problema, teoría, medición, análisis, interpretación y reporte.	Permite que el modelo SEM sea defendible como producto científico integral.	Si una fase se debilita, el modelo completo pierde solidez.	Hair et al. (2019); Hair et al. (2021)
Comparación de modelos	Evaluación de modelos alternativos para determinar cuál ofrece mejor equilibrio entre teoría, parsimonia,	Ayuda a justificar la arquitectura final del modelo frente a configuraciones rivales.	Debe basarse en alternativas teóricamente defendibles, no en prueba y error.	Dijkstra & Henseler (2015); Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	explicación y predicción.			
Constructo	Entidad teórica no observable directamente que se representa mediante indicadores.	Es la unidad conceptual central del modelo SEM.	Debe definirse con claridad antes de seleccionar indicadores o estimar relaciones.	Churchill (1979); Jarvis et al. (2003)
Contribución académica	Aporte que el estudio realiza al conocimiento teórico, metodológico, empírico o práctico.	Permite justificar el valor del modelo como producto de investigación.	Debe responder al vacío identificado al inicio del estudio.	Corley & Gioia (2011); Whetten (1989)
Contribución empírica	Evidencia aportada en una muestra, contexto, sector, población o fenómeno específico.	Refuerza la pertinencia contextual del modelo.	Es relevante cuando aporta datos en contextos poco estudiados o con evidencia limitada.	Gregor (2006); Corley & Gioia (2011)
Contribución metodológica	Aporte relacionado con medición, especificación, análisis, predicción, comparación o reporte del modelo.	Mejora la forma de construir, evaluar o interpretar modelos SEM/PLS-SEM.	No consiste solo en usar software, sino en justificar mejor decisiones metodológicas.	Henseler (2017); Guenther et al. (2023)
Contribución práctica	Implicación útil para organizaciones, directivos, instituciones, docentes, usuarios o tomadores de decisiones.	Traduce los resultados del modelo en orientaciones aplicables.	Debe derivarse directamente de los hallazgos y no de recomendaciones genéricas.	Corley & Gioia (2011); Colquitt & George (2011)
Contribución teórica	Aporte que confirma, amplía, refina, cuestiona o integra conocimiento previo.	Conecta los resultados SEM/PLS-SEM con la literatura y el vacío investigado.	Debe explicar qué se comprende mejor gracias al modelo.	Whetten (1989); Corley & Gioia (2011)
Criterios de evaluación	Conjunto de indicadores usados para valorar medición, estructura, hipótesis,	Ordenan la interpretación metodológica del estudio.	Deben declararse antes de presentar resultados para evitar decisiones improvisadas.	Hair et al. (2019); Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
	predicción y comparación del modelo.			
Discusión	Sección donde se interpretan los resultados a la luz de la teoría, el problema, el contexto y los hallazgos previos.	Convierte los resultados estadísticos en conocimiento argumentado.	No debe repetir resultados; debe explicar qué significan.	Gregor (2006); Hair et al. (2019)
Diseño de investigación	Estructura metodológica del estudio: transversal, longitudinal, explicativo, predictivo, correlacional o causal-predictivo.	Delimita el alcance de las inferencias del modelo.	Un diseño transversal permite evaluar relaciones estructurales, pero exige prudencia causal.	Shmueli (2010); Gefen et al. (2000)
Efecto directo	Relación inmediata entre un antecedente y una variable dependiente.	Permite evaluar rutas estructurales directas dentro del modelo.	Se interpreta por signo, magnitud, significancia y coherencia teórica.	Hair et al. (2021)
Efecto indirecto	Relación transmitida por una variable mediadora.	Explica mecanismos mediante los cuales ocurre una relación.	Debe evaluarse con *bootstrapping* e intervalos de confianza.	Nitzl et al. (2016)
Efecto total	Suma del efecto directo y los efectos indirectos de un constructo sobre otro.	Permite valorar la influencia global de un predictor dentro del modelo.	Es útil cuando existen mediaciones y relaciones complejas.	Nitzl et al. (2016); Hair et al. (2021)
Enfoque cuantitativo	Perspectiva metodológica basada en medición numérica, variables, constructos, indicadores y análisis estadístico.	Permite evaluar relaciones estructurales mediante SEM/PLS-SEM.	Debe justificarse por la naturaleza de la pregunta estructural y los datos disponibles.	Gefen et al. (2000); Hair et al. (2019)
Especificación del modelo	Definición de constructos, indicadores, relaciones, direcciones, mediaciones, moderaciones y tipo de medición.	Establece la arquitectura que será estimada y evaluada.	Debe realizarse antes del análisis y con fundamento teórico.	Jarvis et al. (2003); Hair et al. (2021)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Futuras líneas de investigación	Propuestas para ampliar, validar, comparar o profundizar el modelo en estudios posteriores.	Proyectan el conocimiento generado hacia nuevas investigaciones.	Deben derivarse de hallazgos y limitaciones, no de posibilidades genéricas.	Hult et al. (2018); Guenther et al. (2023)
Hipótesis estructural	Proposición evaluable que expresa una relación esperada entre constructos.	Traduce el marco relacional en una ruta susceptible de contraste empírico.	Debe tener dirección, fundamento teórico y posibilidad de evaluación estadística.	Gefen et al. (2000); Hair et al. (2021)
Indicador	Variable observable, ítem o medida empírica que representa un constructo.	Permite traducir conceptos abstractos en datos analizables.	Debe derivarse del dominio conceptual del constructo y corresponder a la unidad de análisis.	Churchill (1979); Jarvis et al. (2003)
Interpretación de resultados	Explicación del significado de coeficientes, índices, efectos, hipótesis, predicción y comparación.	Conecta los resultados estadísticos con la teoría, el problema y el contexto.	Debe evitar tanto la sobreinterpretación como la lectura mecánica de resultados.	Hair et al. (2019); Bem (2004)
Limitaciones del estudio	Restricciones asociadas al diseño, muestra, medición, sesgos, contexto, generalización o inferencia causal.	Delimitan el alcance de las conclusiones del modelo.	Reconocer limitaciones aumenta la credibilidad del estudio.	Podsakoff et al. (2024); Shmueli (2010)
Mediación	Relación en la que una variable transmite el efecto de un antecedente hacia una consecuencia.	Permite explicar cómo o por qué ocurre una relación estructural.	Debe interpretarse como mecanismo teórico, no solo como efecto indirecto significativo.	Nitzl et al. (2016)
Método de análisis	Técnica utilizada para estimar y evaluar el modelo, como PLS-SEM.	Permite implementar empíricamente la arquitectura conceptual del modelo.	Debe elegirse por congruencia con objetivo, constructos, datos y propósito analítico.	Hair et al. (2019); Henseler (2017)
Modelo de medición	Parte del modelo que define cómo los indicadores representan a los constructos.	Permite evaluar la calidad empírica de la operacionalización.	Debe revisarse antes de interpretar relaciones estructurales.	Fornell & Larcker (1981); Henseler et al. (2015)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Modelo estructural	Parte del modelo SEM que representa las relaciones entre constructos.	Permite contrastar hipótesis, efectos, capacidad explicativa y predictiva.	Debe derivarse del marco relacional y no del software.	Chin (1998); Hair et al. (2021)
Modelo evaluado	Modelo que ya fue sometido a criterios de medición, estructura, hipótesis, predicción y comparación.	Representa el resultado empírico del proceso de investigación estructural.	Debe interpretarse como evidencia situada, no como verdad definitiva.	Hair et al. (2021); Guenther et al. (2023)
Modelo SEM como producto científico	Resultado integral que articula problema, teoría, constructos, indicadores, hipótesis, análisis e interpretación.	Convierte el modelo estructural en una aportación académica verificable y defendible.	Su valor depende de la trazabilidad conceptual, metodológica y empírica.	Whetten (1989); Hair et al. (2019)
Modelo parsimonioso	Modelo que incluye solo los constructos y relaciones necesarios para responder la pregunta de investigación.	Evita complejidad innecesaria y mejora la interpretación.	Un modelo más simple puede ser preferible si explica o predice suficientemente.	Hair et al. (2021); Dijkstra & Henseler (2015)
Moderación	Relación donde una variable modifica la intensidad o dirección entre un predictor y una variable dependiente.	Permite analizar condiciones bajo las cuales cambia una relación.	Responde al cuándo, para quién o bajo qué condiciones ocurre una relación.	Hair et al. (2021)
Operacionalización	Proceso de convertir conceptos y constructos en indicadores, ítems, escalas o medidas observables.	Hace posible medir los constructos y estimar el modelo SEM/PLS-SEM.	Debe mantener trazabilidad entre concepto, dimensión, indicador e ítem.	Churchill (1979); Jarvis et al. (2003)
Parsimonia	Principio que recomienda evitar variables, relaciones o modelos innecesariamente complejos.	Mejora la claridad, estabilidad e interpretación del modelo.	No significa simplificar en exceso, sino incluir lo necesario y suficiente.	Hair et al. (2021); Dijkstra & Henseler (2015)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
PLS-SEM	Modelado de ecuaciones estructurales por mínimos cuadrados parciales, orientado a explicación de varianza, predicción y modelos complejos.	Permite estimar modelos con constructos reflectivos, formativos o compuestos.	Debe justificarse por objetivo, tipo de constructo, complejidad y orientación predictiva.	Hair et al. (2019); Hair et al. (2021)
Poder predictivo	Capacidad del modelo para anticipar valores de constructos objetivo con error razonable.	Permite evaluar utilidad aplicada del modelo.	Debe analizarse con PLSpredict, RMSE, MAE y Q^2 _predict cuando el estudio sea predictivo.	Shmueli et al. (2019)
Pregunta estructural	Pregunta que expresa una relación entre constructos y orienta el modelo.	Organiza objetivos, hipótesis, variables, medición y análisis.	Debe contener una variable resultado y relaciones modelables.	Gefen et al. (2000); Shmueli (2010)
Preparación de datos	Revisión de datos faltantes, inconsistencias, valores extremos, codificación e idoneidad de la base.	Asegura que el análisis SEM/PLS-SEM se realice con datos adecuados.	Debe reportarse antes de la estimación para fortalecer transparencia metodológica.	Hair et al. (2021)
Problema de investigación	Tensión científica que justifica el estudio: vacío, contradicción, insuficiencia o necesidad práctica.	Da origen al modelo y orienta la selección de variables y relaciones.	El modelo debe responder directamente al problema formulado.	Gregor (2006); Whetten (1989)
Producto de investigación	Resultado académico comunicable, como tesis, artículo, capítulo de libro o informe empírico.	Convierte el análisis SEM/PLS-SEM en conocimiento verificable.	Debe integrar metodología, resultados, discusión, contribuciones y límites.	Bem (2004); Colquitt & George (2011)
Prudencia causal	Cuidado al interpretar relaciones estructurales como causales, especialmente con datos transversales.	Evita conclusiones que excedan el diseño del estudio.	Conviene usar términos como relación estructural, efecto estimado o influencia teóricamente esperada.	Shmueli (2010); Podsakoff et al. (2024)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
Recolección de datos	Procedimiento mediante el cual se obtiene la información empírica del estudio.	Proporciona la base para estimar el modelo SEM/PLS-SEM.	Debe describir periodo, medio, participantes, criterios éticos y condiciones de aplicación.	Podsakoff et al. (2024); Hair et al. (2021)
Redacción metodológica	Forma de presentar y justificar el enfoque, diseño, muestra, instrumento, técnica y criterios analíticos.	Permite evaluar la calidad y replicabilidad del estudio.	Debe ser precisa, sobria, ordenada y verificable.	Bem (2004); Guenther et al. (2023)
Reporte SEM/PLS-SEM	Presentación ordenada de medición, estructura, hipótesis, efectos, predicción y comparación.	Comunica los resultados del modelo como evidencia científica.	No debe copiar salidas del software; debe interpretar resultados con teoría y contexto.	Hair et al. (2019); Hair et al. (2021)
Resultados no apoyados	Hipótesis o relaciones que no reciben evidencia empírica suficiente.	Permiten identificar límites teóricos, contextuales o metodológicos.	No deben ocultarse; pueden generar nuevas preguntas de investigación.	Guenther et al. (2023); Hair et al. (2019)
Resultados apoyados	Hipótesis o relaciones que reciben evidencia empírica favorable.	Permiten sostener provisionalmente relaciones propuestas en el modelo.	Deben interpretarse por magnitud, sentido teórico y relevancia sustantiva.	Hair et al. (2021); Gefen et al. (2000)
Sesgo de método común	Sesgo producido cuando los datos provienen de la misma fuente, instrumento o momento de medición.	Puede inflar o distorsionar relaciones entre constructos.	Debe prevenirse mediante diseño y, cuando sea posible, diagnosticarse estadísticamente.	Podsakoff et al. (2024); Kock (2015)
Software SEM/PLS-SEM	Herramienta computacional usada para estimar y evaluar el modelo, como SmartPLS, ADANCO, WarpPLS, SEMinR o cSEM.	Implementa el método seleccionado, pero no sustituye la justificación conceptual.	Debe mencionarse después de justificar la técnica metodológica.	Henseler (2017); Hair et al. (2019)
Tamaño de muestra	Número de observaciones utilizadas para estimar el modelo.	Afecta estabilidad estadística, potencia y confiabilidad de resultados.	Debe justificarse con criterios de potencia, complejidad del modelo y	Cohen (1992); Kock & Hadaya (2018)

Concepto / índice	Significado detallado	Función dentro del modelo SEM	Interpretación o criterio orientativo	Referencias
			predictores principales.	
Técnica SEM/PLS-SEM	Enfoque analítico seleccionado para evaluar relaciones entre constructos.	Permite contrastar empíricamente el modelo estructural.	Debe elegirse por coherencia con propósito, medición, teoría y datos.	Hair et al. (2019); Chin (1998)
Transparencia académica	Claridad con que se reportan decisiones, procedimientos, resultados, limitaciones y criterios.	Permite evaluar, replicar y cuestionar el estudio.	Es condición central para tesis, artículos y capítulos de investigación.	Bem (2004); Hair et al. (2019)
Trazabilidad	Capacidad de rastrear cada decisión del modelo desde el problema hasta los resultados.	Permite defender la coherencia entre teoría, medición, hipótesis y análisis.	Cada constructo, indicador y relación debe poder justificarse.	Whetten (1989); Colquitt & George (2011)
Unidad de análisis	Nivel empírico al que pertenecen los datos: individuo, equipo, empresa, institución, proyecto o región.	Define cómo se interpretan constructos, indicadores y relaciones.	Debe ser coherente con el instrumento, la muestra y las hipótesis.	Gefen et al. (2000); Hair et al. (2021)
Vacío de conocimiento	Ausencia, insuficiencia, contradicción o necesidad no resuelta en la literatura o práctica.	Justifica la construcción del modelo y la contribución del estudio.	Puede ser teórico, empírico, metodológico o práctico.	Gregor (2006); Corley & Gioia (2011)

Fuente: recopilación y elaboración propia

REFERENCIAS

Becker, J.-M., Klein, K., & Wetzels, M. (2012). Hierarchical latent variable models in PLS-SEM: Guidelines for using reflective-formative type models. Long Range Planning, 45(5–6), 359–394. https://doi.org/10.1016/j.lrp.2012.10.001

Bem, D. J. (2004). Writing the empirical journal article. En J. M. Darley, M. P. Zanna, & H. L. Roediger III (Eds.), The compleat academic: A career guide (2nd ed., pp. 185–219). American Psychological Association. https://doi.org/10.1037/10726-008

Cepeda-Carrion, G., Nitzl, C., & Roldán, J. L. (2017). Mediation analyses in partial least squares structural equation modeling: Guidelines and empirical examples. En H. Latan & R. Noonan (Eds.), Partial least squares *path* modeling: Basic concepts, methodological issues and applications (pp. 173–195). Springer. https://doi.org/10.1007/978-3-319-64069-3_8

Cheah, J.-H., Nitzl, C., Roldán, J. L., Cepeda-Carrion, G., & Gudergan, S. P. (2021). A primer on the conditional mediation analysis in PLS-SEM. *The DATA BASE for Advances in Information Systems,* *52*(SI), 43–100. https://doi.org/10.1145/3505639.3505645

Chin, W. W. (1998). The partial least squares approach to structural equation modeling. En G. A. Marcoulides (Ed.), *Modern methods for business research* (pp. 295–336). Lawrence Erlbaum. https://www.researchgate.net/publication/311766005_The_Partial_Least_Squares_Approach_to_Structural_Equation_Modeling

Churchill, G. A. (1979). A paradigm for developing better measures of marketing constructs. *Journal of Marketing Research, 16*(1), 64–73. https://nguyenthanhphuong.com/wp-content/uploads/2026/02/Churchill-1979.pdf

Cohen, J. (1992). A power primer. *Psychological Bulletin, 112*(1), 155–159. https://www2.psych.ubc.ca/~schaller/528Readings/Cohen1992.pdf

Colquitt, J. A., & George, G. (2011). *Publishing in AMJ—Part 1: Topic choice.* Academy of Management Journal, 54(3), 432–435. https://doi.org/10.5465/amj.2011.61965960

Corley, K. G., & Gioia, D. A. (2011). Building theory about theory building: What constitutes a theoretical contribution? Academy of Management Review, 36(1), 12–32. https://doi.org/10.5465/amr.2009.0486

Diamantopoulos, A., & Winklhofer, H. M. (2001). Index construction with formative indicators: An alternative to scale development. *Journal of Marketing Research, 38*(2), 269–277 https://statmath.wu.ac.at/courses/r-se-mbr/dl/M1b_Diamantopoulos_2001.pdf

Dijkstra, T. K., & Henseler, J. (2015). Consistent partial least squares *path* modeling. *MIS Quarterly, 39*(2), 297–316. https://doi.org/10.25300/MISQ/2015/39.2.02

Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research, 18*(1), 39–50. https://doi.org/10.1177/002224378101800104

Gefen, D., Straub, D. W., & Boudreau, M.-C. (2000). Structural equation modeling and regression: Guidelines for research practice. *Communications of the Association for Information Systems, 4*, Article 7. https://cits.tamiu.edu/kock/nedwebarticles/gefenetal2000.pdf

Green, S. B. (1991). How many subjects does it take to do a regression analysis? *Multivariate Behavioral Research, 26*(3), 499–510. https://parsmodir.com/wp-content/uploads/2013/03/green1991.pdf

Gregor, S. (2006). The nature of theory in information systems. *MIS Quarterly, 30*(3), 611–642. https://doi.org/10.2307/25148742

Gudergan, S. P., Ringle, C. M., Wende, S., & Will, A. (2008). Confirmatory tetrad analysis in PLS *path* modeling. *Journal of Business Research, 61*(12), 1238–1249. https://doi.org/10.1016/j.jbusres.2008.01.012

Guenther, P., Guenther, M., Ringle, C. M., Zaefarian, G., & Cartwright, S. (2023). Improving PLS-SEM use for business marketing research. *Industrial Marketing Management, 111*, 127–142. PDF: https://eprints.whiterose.ac.uk/id/eprint/200118/

Hair, J. F., Hult, G. T. M., Ringle, C. M., Sarstedt, M., Danks, N. P., & Ray, S. (2021). *Partial least squares structural equation modeling (PLS-SEM) using R*. Springer. https://link.springer.com/book/10.1007/978-3-030-80519-7

Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review, 31*(1), 2–24.

https://htw.oil.com.tw/web/cycuim/phd/asset/phd09/Romi_2019_Hairetal_EBR_PLS-SEM.pdf

Hayes, A. F. (2015). An index and test of linear moderated mediation. *Multivariate Behavioral Research, 50*(1), 1–22. https://doi.org/10.1080/00273171.2014.962683

Henseler, J. (2017). Bridging design and behavioral research with variance-based structural equation modeling. *Journal of Advertising, 46*(1), 178–192. PDF: https://ris.utwente.nl/ws/files/6995998/2017_JA_Henseler.pdf

Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science, 43*, 115–135.: https://run.unl.pt/server/api/core/bitstreams/d124ea66-0ba4-4c13-a658-af460fbce714/content

Henseler, J., Ringle, C. M., & Sarstedt, M. (2016). Testing measurement invariance of composites using partial least squares. *International Marketing Review, 33*(3), 405–431. https://doi.org/10.1108/IMR-09-2014-0304

Hult, G. T. M., Hair, J. F., Jr., Proksch, D., Sarstedt, M., Pinkwart, A., & Ringle, C. M. (2018). Addressing endogeneity in international marketing applications of partial least squares structural equation modeling. *Journal of International Marketing, 26*(3), 1–21. https://doi.org/10.1509/jim.17.0151

Jarvis, C. B., MacKenzie, S. B., & Podsakoff, P. M. (2003). A critical review of construct indicators and measurement model misspecification in marketing and consumer research. *Journal of Consumer Research, 30*(2), 199–218. https://statmath.wu.ac.at/courses/r-se-mbr/dl/M1c_Jarvis_Mackenzie_Podsakoff_2003.pdf

Kock, N. (2015). Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of e-Collaboration, 11*(4), 1–10. https://cits.tamiu.edu/kock/pubs/journals/2015JournalIJeC_CommMethBias/Kock_2015_IJeC_CommonMethodBiasPLS.pdf

Kock, N., & Hadaya, P. (2018). Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. *Information Systems Journal, 28*(1), 227–261. https://cits.tamiu.edu/kock/pubs/journals/2018/Kock_Hadaya_2018_ISJ_SampleSizePLS.pdf

Kock, N., & Lynn, G. S. (2012). Lateral collinearity and misleading results in variance-based SEM: An illustration and recommendations. *Journal of the Association for Information Systems, 13*(7), 546–580. https://doi.org/10.17705/1jais.00302

Mejía-Trejo, J. (2023). *Diseño de cuestionarios para la creación de escalas en las ciencias sociales: Uso del análisis factorial exploratorio (SPSS) y confirmatorio (EQS)*. AMIDI. ISBN 978-607-59397-6-6. https://amidibiblioteca.amidi.mx/index.php/AB/catalog/book/49

Nitzl, C., Roldán, J. L., & Cepeda, G. (2016). Mediation analysis in partial least squares *path* modeling. *Industrial Management & Data Systems, 116*(9), 1849–1864. https://doi.org/10.1108/IMDS-07-2015-0302

Podsakoff, P. M., Podsakoff, N. P., Williams, L. J., Huang, C., & Yang, J. (2024). Common method bias: It's bad, it's complex, it's widespread, and it's not easy to

fix. *Annual Review of Organizational Psychology and Organizational Behavior, 11*, 17–61. https://www.annualreviews.org/doi/pdf/10.1146/annurev-orgpsych-110721-040030

Reinartz, W., Haenlein, M., & Henseler, J. (2009). An empirical comparison of the efficacy of covariance-based and variance-based SEM. *International Journal of Research in Marketing, 26*(4), 332–344. PDF: https://flora.insead.edu/fichiersti_wp/inseadwp2009/2009-44.pdf

Richter, N. F., Schubring, S., Hauff, S., Ringle, C. M., & Sarstedt, M. (2020). When predictors of outcomes are necessary: Guidelines for the combined use of PLS-SEM and NCA. *Industrial Management & Data Systems, 120*(12), 2243–2267. https://doi.org/10.1108/IMDS-11-2019-0638

Ringle, C. M., Sarstedt, M., & Straub, D. W. (2012). Editor's comments: A critical look at the use of PLS-SEM in MIS Quarterly. *MIS Quarterly, 36*(1), iii–xiv. https://doi.org/10.2307/41410402

Ringle, C. M., & Sarstedt, M. (2016). Gain more insight from your PLS-SEM results: The importance-performance map analysis. *Industrial Management & Data Systems, 116*(9), 1865–1886. https://doi.org/10.1108/IMDS-10-2015-0449

Sarstedt, M., Hair, J. F., Jr., Cheah, J.-H., Becker, J.-M., & Ringle, C. M. (2019). How to specify, estimate, and validate higher-order constructs in PLS-SEM. *Australasian Marketing Journal, 27*(3), 197–211. https://doi.org/10.1016/j.ausmj.2019.05.003

Sarstedt, M., Richter, N. F., Hauff, S., & Ringle, C. M. (2024). Combined importance–performance map analysis (cIPMA) in partial least squares structural equation modeling (PLS–SEM): A SmartPLS 4 tutorial. *Journal of Marketing Analytics, 12*(4), 746–760. https://doi.org/10.1057/s41270-024-00325-y

Schuberth, F., Rademaker, M. E., & Henseler, J. (2020). Estimating and assessing second-order constructs using PLS-PM: The case of composites of composites. *Industrial Management & Data Systems, 120*(12), 2211–2241. https://doi.org/10.1108/IMDS-12-2019-0642

Shmueli, G. (2010). To explain or to predict? *Statistical Science, 25*(3), 289–310. https://doi.org/10.1214/10-STS330 PDF: https://www.stat.berkeley.edu/~aldous/157/Papers/shmueli.pdf

Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: Guidelines for using PLSpredict. *European Journal of Marketing, 53*(11), 2322–2347. https://doi.org/10.1108/EJM-02-2019-0189

Whetten, D. A. (1989). What constitutes a theoretical contribution? *Academy of Management Review, 14*(4), 490–495. https://doi.org/10.5465/amr.1989.4308371

De la idea al modelo estructural:
Investigación conceptual en ciencias de la administración

© 2026 Academia Mexicana de Investigación y Docencia en Innovación (AMIDI)

Maquetación, diseño y distribución digital:
Academia Mexicana de Investigación y Docencia en Innovación (**AMIDI**).
Responsable del registro DOI, la gestión de metadatos y la publicación en EL repositorio de AMIDI.Biblioteca perteneciente a Editorial AMIDI

Av.Paseo de los Virreyes 920,
Col. Virreyes Residencial
C.P. 45110
Zapopan, Jalisco, México

eBook Hecho y editado en México / Made and edited in Mexico
Se terminó de editar en **Mayo de 2026**

Zapopan, Jal. a 17 de marzo de 2026

Dictamen de Obra

Los miembros del equipo editorial de la Academia Mexicana de Investigación y Docencia en Innovación (**AMIDI**), **RENIECYT-SECIHTI 2200092**, ver:
https://www.amidibiblioteca.amidi.mx/index.php/AB/about/editorialTeam
se reunieron para atender la invitación a dictaminar el libro:

De la idea al modelo estructural:
Investigación conceptual en ciencias de la administración

La obra dictaminada corresponde al siguiente autor:

Nombre completo	Rol
Mejía-Trejo Juan	Autor

La obra fue sometida al proceso de evaluación por pares doble ciego, de acuerdo a la política de la editorial, para su dictaminación de aceptación, ver: https://www.amidibiblioteca.amidi.mx/index.php/AB/procesodeevaluacionporparesenciego
El equipo editorial, en coordinación con el curador principal del repositorio digital, realizó las siguientes acciones:

1. El comité científico, de forma colegiada, revisó los contenidos y propuso a los pares evaluadores que colaboran dentro del comité de redacción, tomando en cuenta su especialidad, pertinencia, argumentos, enfoque de los capítulos al tema central del libro, entre otros.
2. Se invitó a los pares evaluadores a participar, formalizando su colaboración.
3. Se envió el formato de evaluación para el inicio del proceso de evaluación doble ciego a los evaluadores elegidos de la mencionada obra.
4. El comité científico recibió las evaluaciones de los pares evaluadores e informó **al autor** los resultados a fin de atender las observaciones, el requerimiento de reducción de similitudes y las recomendaciones de mejora a la obra.
5. La obra evaluada, constó de:

CONTENIDO
Sobre el autor
INTRODUCCIÓN
CAPÍTULO 1. La idea antes del modelo
De la idea al fenómeno investigable
Del fenómeno al problema estructural
De la pregunta a la relación estructural
De los conceptos a las variables y constructos
Viabilidad conceptual, empírica y metodológica del estudio

Av. Lázaro Cárdenas 3454 int. 6,
Col. Jardines de los Arcos, C.P. 44500,
Guadalajara, Jalisco, México
Tel. Oficina. 33 3560 7860/ Cel. 3326264422
editorial@scientiaetpraxis.amidi.mx

Conclusiones
CAPÍTULO 2. Sistema conceptual y lógica del modelo
Del problema de investigación al sistema conceptual
Tipos de vacío: teórico, empírico, metodológico y práctico
Explicación, predicción y lógica del modelo
Relaciones conceptuales: antecedentes, consecuencias y mecanismos
Construcción del sistema conceptual preliminar antes del modelo SEM
Conclusiones
CAPÍTULO 3. De la teoría a las variables
De la teoría al marco relacional
Variable dependiente y variables explicativas
Panorama de las técnicas SEM y lógica de modelación estructural
Hipótesis del modelo: contraste, significancia y apoyo empírico
Representación gráfica, trazabilidad y coherencia interna del modelo estructural
Conclusiones
CAPÍTULO 4. Del concepto al constructo medible
Concepto, variable, constructo
Constructos latentes y variables observables
Dimensionalidad del constructo
Desarrollo inicial de escala
Especificación conceptual antes de medir
Conclusiones
CAPÍTULO 5. PLS-SEM, del constructo al indicador
Constructos reflectivos, formativos, compuestos y jerárquicos
Confiabilidad y validez convergente en constructos reflectivos
Validez discriminante y diferenciación empírica entre constructos
Colinealidad, sesgo de método común y calidad de los indicadores
Tamaño de muestra, potencia estadística y viabilidad del modelo
Conclusiones
CAPÍTULO 6. Robustez, mediación, moderación, MICOM, MGA y reporte
Robustez y estabilidad del modelo estructural
Mediación, moderación y efectos complejos en PLS-SEM
Invariancia y análisis multigrupo en PLS-SEM
Evaluación del poder predictivo del modelo
Comparación de modelos
Conclusiones
CAPÍTULO 7. Del modelo SEM al producto de investigación
Fin del proceso: de la idea al modelo evaluado
Construcción del modelo SEM como producto científico
Apartado metodológico para tesis, artículo o capítulo de libro
Presentación e interpretación de resultados SEM/PLS-SEM
Discusión, contribuciones, limitaciones y futuras líneas de investigación
Conclusiones
REFERENCIAS

6. Una vez emitidas las observaciones, el requerimiento de reducción de similitudes, y recomendaciones de mejora a la obra por los evaluadores y todas ellas resueltas por el **autor**, se determina que el contenido del libro:

    a. Reúne los elementos teóricos actualizados y prácticos desglosados en cada uno de sus capítulos.
    b. Los capítulos contenidos en la obra, muestran claridad en el dominio del tema, congruencia con el título central del libro, y una estructura consistente
    c. Se concluye finalmente, que la obra dictaminada, puede fungir como libro de texto principal o de apoyo tanto para estudiantes de licenciatura como de posgrados, así como público en general interesado.

7. De esta forma, el resultado del dictamen de aceptación de la obra fue:

FAVORABLE PARA SU PUBLICACIÓN

Sirva la presente constancia para los fines académicos, editoriales y administrativos que al interesado convengan.

Atentamente

Dr. Carlos Omar Aguilar-Navarro
Curador AMIDI.Biblioteca
Editorial AMIDI

Av. Lázaro Cárdenas 3454 int. 6,
Col. Jardines de los Arcos, C.P. 44500,
Guadalajara, Jalisco, México
Tel. Oficina. 33 3560 7860/ Cel. 3326264422
editorial@scientiaetpraxis.amidi.mx