

Manuel Anchapuri Quispe



APLICACIÓN DE MODELOS DE
ECUACIONES ESTRUCTURALES:
Para ciencias empresariales



Manuel Anchapuri Quispe

**Aplicación de modelos de ecuaciones
estructurales: Para ciencias empresariales.**

Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales.

Autor:

Manuel Anchapuri Quispe

Editor

Manuel Anchapuri Quispe

Av. La torre Nro 773

manchapuri@unap.edu.pe

Puno – Perú

Primera edición, febrero de 2026

DEPÓSITO LEGAL DEL LIBRO ELECTRÓNICO N° **2026-00019**
ISBN N° **978-612-03-1882-9**

Disponible en: <https://demokno.info/publicaciones/>

Diseño y diagramación

Micol Zayetsy Anchapuri Ramos

Diseño de cubierta:

Manuel Anchapuri Q.

Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales

Manuel Anchapuri Quispe

Como Referenciar:

Anchapuri Quispe, M. (2026). *Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales*. Demokno.

<https://demokno.info/publicaciones/>



Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales © 2026 by Anchapuri Quispe, M., is licensed under Creative Commons Attribution-ShareAlike 4.0 International Para ver una copia de esta licencia, visite <https://creativecommons.org/licenses/by-sa/4.0/>

“La mejor venganza es ser diferente a quien causó el daño.”

“Nada tiene tanto poder para ampliar la mente que la capacidad de investigar de manera sistemática y real todo lo que es susceptible de observación en la vida”

Marco Aurelio,

“Mientras se pospone, la vida pasa.” Séneca

“Los datos no son más que resúmenes de miles de historias; cuenta algunas de esas historias para que los datos cobren sentido.” — Dan Heath

Dedicatoria:

A la familia, por su apoyo incondicional y por recordarme que la constancia es la base de toda construcción intelectual.

A mis estudiantes e investigadores, quienes con sus preguntas, inquietudes y desafíos impulsan la búsqueda permanente de nuevo conocimiento.

Y a todas las personas que creen en la ciencia como motor de transformación social, gerencial y humana.

Pensamiento:

*"Nunca te despojes de toda
defensa, porque tarde o temprano
serás atacado por los que antes te
respetaban".*

*“Solo viviré una vez; por
lo tanto, Cuánto bien haga y
cuanta bondad pueda mostrar a un
Ser Humano, he de hacerlo ahora.
No debe aplazarlo ni olvidarlo,
Pues no volveré a pasar por aquí”.*

PRESENTACIÓN DEL LIBRO

Por el autor

La presente obra, *Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales*, nace de la necesidad de ofrecer a la comunidad académica y profesional un recurso integral, riguroso y orientado a la práctica investigativa. A lo largo de mi experiencia como docente y gestor académico, he observado cómo el Modelado de Ecuaciones Estructurales se ha convertido en una herramienta esencial para comprender la complejidad organizacional y para sustentar decisiones estratégicas basadas en datos.

Este libro surge con el propósito de tender un puente entre la teoría y la aplicación, entre la estadística avanzada y la realidad empresarial. Su contenido está diseñado para guiar al lector desde los fundamentos filosóficos del SEM hasta su implementación en escenarios reales, incorporando métodos reflexivos, formativos, estructurales e interactivos. Además, integra una perspectiva contemporánea basada en la ciencia abierta, que considero indispensable para el avance del conocimiento y la transparencia metodológica.

Los casos de estudio incluidos constituyen un esfuerzo por demostrar que el SEM no es únicamente una técnica estadística, sino una herramienta estratégica capaz de generar ventajas competitivas, optimizar procesos organizacionales y ofrecer diagnósticos precisos en mercados

cambiantes. Estos casos reflejan diversas realidades empresariales y están orientados a fortalecer la capacidad analítica del lector.

Invito a quienes leen estas páginas a explorarlas con espíritu crítico y con la disposición de llevar estas metodologías a sus propios contextos de investigación o gestión. Confío en que este libro contribuirá al fortalecimiento de la investigación científica y a la consolidación de una cultura analítica avanzada en las ciencias empresariales.

Con aprecio académico y compromiso con la excelencia científica,

Manuel Anchapuri

Índice

PRESENTACIÓN DEL LIBRO	10
Índice	12
INTRODUCCIÓN	23
PRÓLOGO	28

CAPITULO I

FUNDAMENTOS DEL SEM: FILOSOFÍA Y ALCANCE

1.1	Definición y alcance del modelado de ecuaciones estructurales	33
1.1	De la regresión al SEM (técnicas de 1ra vs. 2da generación)	34
1.2	Anatomía del Modelo	35
1.1.1	Tipos de variables SEM	35
1.1.2	Arquitectura y componentes de un modelo SEM	37
1.1.3	Especificación del Modelo de Medida: Reflectivo vs. Formativo	39
1.1.4	Términos de Error	42
1.2	Fundamentos teóricos del SEM	44
1.3	Paradigmas del SEM: Covarianza (CB-SEM) vs. Varianza (PLS-SEM)	45
1.3.1	El Enfoque Confirmatorio: CB-SEM (Covariance-Based)	46
1.3.2	El Enfoque Predictivo: PLS-SEM (Partial Least Squares)	47
1.3.3	Marco de Decisión	48
1.4	Justificación del Enfoque PLS-SEM en ciencias empresariales	49
1.4.1	PLS-SEM en Ciencias Empresariales	49

1.4.2	La importancia de predecir constructos	49
1.5	Aplicabilidad gerencial y estratégica	50
1.6	Entorno informático SEM	51
1.6.1	PLS-SEM (Enfoque basado en la varianza)	51
1.6.2	CB-SEM (Enfoque basado en la covarianza)	52

CAPITULO II

DISEÑO DE INVESTIGACIÓN Y ESTRATEGIA MUESTRAL

2.1	Decisión analítica: el marco estratégico	57
2.2	Teoría del muestreo en SEM: calidad y robustez	58
2.3	Potencia estadística (1-beta) y decisiones metodológicas	60
2.1.1	El Estándar de Oro: El umbral del 80%	60
2.1.2	Implicaciones Críticas para PLS-SEM	62
2.4	Métodos de estimación del tamaño muestral	63
2.4.1	Nivel 1: Aproximación Heurística	63
2.4.2	Nivel 2: Análisis de Potencia a Priori	64
2.4.3	Nivel 3: Simulaciones y criterios de complejidad	66
2.5	Diseño para la investigación exploratoria y predictiva	68

CAPITULO III

PROTOCOLO DE EVALUACIÓN Y REPORTE DE RESULTADOS

3.1	Fundamentos metodológicos de la validación	74
3.1.1	Los dos niveles de teoría en SEM	74
3.1.2	El Principio de la "Secuencia de Dos Pasos"	76
3.2	Paso 1: Validación del modelo de medida (Outer Model)	77

3.2.1	Confiabilidad del Indicador	78
3.2.2	Consistencia Interna	79
3.2.3	Validez Convergente	80
3.2.4	Validez discriminante	81
3.3	Paso 2: Validación del Modelo Estructural (Inner Model)	81
3.3.1	Evaluación de la Colinealidad (VIF)	82
3.3.2	Evaluación de las Relaciones Causales	83
3.3.3	Coeficiente de Determinación (R2)	84
3.3.4	Tamaño del Efecto (f^2)	84
3.3.5	Relevancia Predictiva (Q2)	85
3.4	Consideraciones sobre el ajuste global y la predicción.	86
3.4.1	Fundamento algorítmico (Incongruencia Matemática)	87
3.4.2	Estado experimental de las métricas alternativas	87
3.4.3	Objetivo Epistemológico (Explicación vs. Predicción)	87
3.5	Síntesis y estándares de reporte académico	88
3.6	Guía de lecturas avanzadas y modelos de referencia	91

CAPITULO IV

MODELADO DE MEDIDA REFLEXIVO

4.1	Operacionalización del Modelo y Diccionario de Variables	99
4.2	Características Distintivas y Lógica Causal	101
4.3	El Algoritmo de Validación: El "Embudo" de Calidad	104
4.4	Paso 1: Fiabilidad Individual del Indicador (Cargas Externas)	105
4.4.1	La Regla Dorada del 0.708	105

4.4.2	La "Zona Gris": Protocolo de depuración de indicadores	106
4.4.3	Aplicación al caso de estudio	107
4.5	Paso 2: Consistencia interna (fiabilidad del constructo)	108
4.5.1	La Tríada de Fiabilidad	109
4.5.2	Criterios de decisión y la paradoja del "exceso de fiabilidad"	110
4.6	Paso 3: Validez Convergente (AVE)	113
4.6.1	Definición y lógica matemática	113
4.6.2	El Umbral crítico: La Regla del 50%	114
4.6.3	Estrategia de corrección (Troubleshooting)	115
4.7	Paso 4: Validez Discriminante (La Prueba de Fuego)	116
4.7.1	La Evolución Metodológica: Del Fornell-Larcker al HTMT	116
4.7.2	Criterios de decisión e inferencia estadística	118
4.8	Reporte de resultados: estándares de publicación	121
4.8.1	La Estructura de la tabla maestra	122
4.8.2	Plantilla de Redacción Narrativa ("Fill-in-the-blanks")	122
4.9	Referencias científicas sobre modelos reflexivos.	126

CAPITULO V

MODELOS FORMATIVOS EN SEM

5.1	Naturaleza y lógica causal de los modelos formativos	134
5.1.1	Diagnóstico estadístico: colinealidad y redundancia	135
5.1.2	Interpretación de parámetros: peso versus carga	136

5.2	Criterios para la especificación de constructos formativos	139
5.2.1	Fundamentos conceptuales para la especificación formativa	140
5.2.2	Generación de indicadores y justificación teórica	140
5.2.3	Validación de contenido mediante juicio experto	142
5.2.4	Evaluación estadística inicial del bloque formativo	143
5.2.5	Decisiones sobre retención, combinación o eliminación de indicadores	144
5.2.6	Ejemplo aplicado: capacidad de absorción organizacional	145
5.3	El Algoritmo de Evaluación de Modelos Formativos	146
5.3.1	Paso 1: Validación Convergente (El filtro de coherencia)	146
5.3.2	Paso 2: Diagnóstico de Colinealidad (El filtro de independencia)	147
5.3.3	Paso 3: Significación y Relevancia (El filtro de contribución)	148
5.3.4	Resumen Ejecutivo de Métricas	148
5.3.5	Protocolo de Depuración: ¿Cuándo eliminar un indicador?	150
5.4	Diseño y validación del instrumento formativo: El Reto de la Convergencia	151
5.4.1	El Desafío de la Validación:	151
5.4.2	Caso Aplicado: Protocolo de Construcción del Modelo de Reputación	152
5.4.3	Procedimiento de Ejecución y Criterios de Decisión	155
5.5	Determinación y Uso de una Variable Proxy	157

5.5.1	Cómo se determina (Selección Teórica)	157
5.5.2	Cómo se calcula (Validación Estadística)	158
5.6	Validez convergente: el análisis de redundancia	158
5.7	Relevancia y significación estadística	163
5.8	Referencias científicas sobre modelos formativos	167

CAPITULO VI

MODELO ESTRUCTURAL:

6.1	Propósito y fundamento	174
6.1.1	Relación con la teoría subyacente	175
6.2	Colinealidad en el modelo estructural	177
6.3	Evaluación de las relaciones hipotetizadas	178
6.3.1	Procedimiento de Bootstrapping	179
6.3.2	Criterios de decisión	179
6.4	Poder explicativo (R^2) y tamaño del efecto (f^2)	180
6.4.1	Coefficiente de determinación (R^2)	180
6.4.2	Tamaño del efecto (f^2)	180
6.5	Relevancia predictiva (Q^2 y PLSpredict)	181
6.5.1	Procedimiento PLSpredict	181
6.6	Significancia y relevancia de relaciones estructurales	182
6.7	Referencias científicas sobre Modelo Estructural	189

CAPITULO VII

MODELOS INTERACCIONALES:

ANÁLISIS DE MEDIACIÓN EN SEM

7.1	Contexto teórico y valor de la mediación causal	195
7.2	Fundamentos y análisis de mediación en modelos SEM	197
7.3	Mediación bajo el enfoque de ecuaciones estructurales	199
7.4	Fundamentos y criterios para la detección de mediación	200
7.5	Presentación e interpretación de resultados	209
7.5.1	Estructura de reporte de coeficientes	209
7.5.2	Reporte de efectos indirectos	210
7.5.3	Redacción	210
7.5.4	Reporte de calidad predictiva	211
7.6	Aclaraciones metodológicas	211
7.7	Referencias científicas sobre mediación	212
	ANÁLISIS DE MODERACIÓN EN SEM	215
7.8	Definición y tipología de la moderación	215
7.9	Clasificación de la moderación	217
7.10	Fundamentos y motivación causal	218
7.11	Metodología para modelar la moderación en SEM	219
7.12	Supuestos, riesgos y medidas preventivas	222
7.13	Preparación de datos para el análisis de moderación en modelos SEM	225
7.14	Ejemplo: Moderación por Costes de Cambio	229
7.15	Referencias científicas sobre moderación	234

CAPITULO VIII

SOFTWARE ESPECIALIZADO Y CIENCIA ABIERTA EN SEM

8.1	Elección entre interfaz gráfica y código	240
-----	--	-----

8.2	Software comercial	241
8.2.1	IBM SPSS AMOS: El Estándar Visual para CB-SEM	241
8.2.2	SmartPLS: El Gigante del Enfoque PLS	242
8.2.3	Mplus: La Potencia Estadística	242
8.3	Software de acceso libre	243
8.3.1	El Ecosistema R: lavaan y semnr	243
8.3.2	Jamovi y JASP: Lo mejor de dos mundos	244
8.4	Escenarios Prácticos de Decisión	244
8.5	Inteligencia Artificial en SEM	246
8.6	Referencias sobre software SEM	247
8.7	Referencias sobre el uso de software SEM	248

CAPITULO IX

ARQUITECTURA DE MODELOS

9.1	Gestión de la Cadena de Suministro (SCM) e Impacto Financiero	255
9.2	El Marketing Mix en Productos de Salud (Decisión de Compra)	258
9.3	Riesgo Crediticio y No-Linealidad (Enfoque Semiparamétrico)	260
9.4	Psicología Educativa y Motivación Investigativa	262
9.5	Marketing en Redes Sociales y Segmentación (Enfoque Híbrido SEM + Machine Learning)	264
9.6	Gestión del Talento Internacional (Inteligencia Cultural)	267
9.7	E-Commerce en Mercados Emergentes (Impulsores vs. Barreras)	269


9.8	E-Commerce y Moda en Mercados Emergentes (Análisis de Barreras y Motivadores)	272
9.9	Arquitectura Empresarial y Transformación Digital	276
9.10	Síntesis global	278
	EPÍLOGO	293
	GLOSARIO	296
	ACRÓNIMOS	298
	Autor	301

INTRODUCCIÓN

El estudio y la gestión de los fenómenos empresariales requieren hoy una aproximación metodológica capaz de integrar constructos latentes, relaciones complejas y estructuras causales robustas. En un entorno caracterizado por la volatilidad, la competencia global y la creciente disponibilidad de datos, el Modelado de Ecuaciones Estructurales (SEM) se ha consolidado como una herramienta central para la investigación científica y la toma de decisiones estratégicas.

Este libro se concibe como una propuesta académica integral, orientada a investigadores, docentes, profesionales y estudiantes de las ciencias empresariales que necesitan un marco sólido para comprender, aplicar y comunicar modelos SEM con rigor técnico y pertinencia práctica. La obra se estructura en ocho capítulos que abarcan desde los fundamentos epistemológicos del SEM hasta su implementación en casos reales de gestión empresarial.

El capítulo inicial desarrolla una reflexión profunda sobre la naturaleza filosófica del SEM y su relevancia para construir teoría en entornos organizacionales. A continuación, se presentan criterios para la toma de decisiones analíticas, con énfasis en la selección entre CB-SEM y PLS-SEM, así como en la importancia del diseño muestral para garantizar la validez del modelo. Los capítulos subsiguientes profundizan en los modelos de medida reflexivos y formativos, ofreciendo protocolos sistemáticos para validar constructos e interpretar resultados.



Posteriormente, se expone el modelo estructural, con especial atención en la relevancia predictiva y el uso de métricas contemporáneas alineadas con estándares internacionales.

El libro incorpora también un capítulo dedicado a los modelos interaccionales (mediación y moderación), esenciales para comprender mecanismos causales complejos en el ámbito empresarial. Asimismo, se incluye un análisis detallado del software especializado y de las prácticas de ciencia abierta, promoviendo la reproducibilidad y la transparencia científica.

La obra culmina con un conjunto de casos de estudio aplicados a diferentes sectores empresariales, los cuales demuestran cómo el SEM permite integrar teoría, datos y decisiones gerenciales. Estas aplicaciones buscan inspirar nuevas líneas de investigación y facilitar la transferencia de metodologías a la práctica profesional.

En conjunto, este libro aspira a consolidarse como un referente académico y técnico para quienes buscan emplear el SEM como instrumento analítico en proyectos de investigación, consultoría, innovación y gestión estratégica. Su enfoque está orientado al futuro y busca fortalecer la capacidad científica de la región mediante una propuesta metodológica rigurosa, accesible y basada en estándares internacionales.

Objetivo del texto

Proporcionar una guía académica integral, metodológicamente rigurosa y orientada a la práctica investigativa, que permita a los investigadores y profesionales de las ciencias empresariales diseñar, estimar, validar e interpretar modelos de ecuaciones estructurales (SEM) mediante técnicas contemporáneas, criterios predictivos y enfoques de ciencia abierta, garantizando resultados reproducibles y aplicables en entornos organizacionales complejos.

Objetivos específicos

1. Fundamentar los principios teóricos y filosóficos del SEM

Explicar la evolución epistemológica del modelado de ecuaciones estructurales, diferenciando enfoques basados en la covarianza y en la varianza, y estableciendo su rol dentro de la investigación avanzada en gestión, economía y ciencias empresariales.

2. Desarrollar criterios analíticos para la toma de decisiones metodológicas

Dotar al lector de herramientas decisionales para seleccionar entre CB-SEM y PLS-SEM, considerando objetivos de investigación, complejidad del modelo, estructura de los datos y exigencias predictivas, además de incorporar lineamientos para un diseño muestral óptimo y estadísticamente robusto.

3. Capacitar en la construcción y validación de modelos de medida reflexivos

Exponer los fundamentos, métricas y procedimientos que aseguran la validez y confiabilidad de los modelos reflexivos, proporcionando protocolos aplicables y sustentados en estándares de investigación.

4. Fortalecer la comprensión y aplicación de los modelos de medida formativos

Presentar los principios teóricos, indicadores críticos y procedimientos operativos para especificar y evaluar constructos formativos, incluyendo el análisis de colinealidad, la interpretación de pesos y la validación por redundancia.

5. Guiar al lector en la evaluación del modelo estructural

Describir y operacionalizar el análisis de las relaciones causales entre constructos, el cálculo de R^2 y f^2 , la significancia mediante *bootstrapping* y la relevancia predictiva mediante PLSpredict, integrando una lectura gerencial orientada al desempeño y la toma de decisiones.

6. Integrar los modelos interaccionales de mediación y moderación

Explicar los fundamentos conceptuales y estadísticos de la mediación y la moderación, así como su utilidad para investigar mecanismos causales y efectos condicionados, proporcionando lineamientos de reporte compatibles con estándares editoriales internacionales.

7. Promover la adopción de software especializado y prácticas de ciencia abierta

Orientar sobre el uso estratégico de herramientas como AMOS, SmartPLS, lavaan y semnr, e impulsar la reproducibilidad científica mediante scripts, repositorios y estándares de documentación propios de la ciencia abierta.

8. Presentar aplicaciones prácticas mediante casos empresariales reales

Mostrar el potencial analítico y predictivo del SEM en áreas clave como marketing, gestión del talento, comercio electrónico, finanzas y transformación digital, mediante casos estructurados que integren teoría, metodología y resultados orientados a la toma de decisiones.

PRÓLOGO

La investigación científica en el campo de las ciencias empresariales se encuentra hoy ante una exigencia ineludible: comprender la complejidad organizacional mediante enfoques analíticos capaces de integrar teoría, datos y predicción. En este escenario, el modelado de ecuaciones estructurales (SEM, por sus siglas en inglés) se ha consolidado como una herramienta metodológica de referencia para estudiar constructos abstractos, relaciones causales y fenómenos multidimensionales que caracterizan a las organizaciones contemporáneas.


Durante décadas, la literatura especializada ha demostrado que el SEM constituye un puente entre la teoría y la práctica gerencial. Tanto los enfoques basados en la covarianza como las metodologías basadas en la varianza han evolucionado para ofrecer análisis robustos y flexibles que permiten al investigador explicar y anticipar comportamientos organizacionales, dinámicas competitivas y patrones de decisión empresarial. En el contexto latinoamericano, esta necesidad es aún más apremiante debido a la heterogeneidad de los mercados, la volatilidad económica y los desafíos estructurales que enfrentan las empresas públicas y privadas.

Este libro responde a esa necesidad con una propuesta académica sólida y orientada al futuro. La obra combina fundamentos epistemológicos, criterios decisionales, procedimientos de validación y análisis predictivo con un enfoque didáctico y accesible. Se articula un conjunto de capítulos

que guían al lector desde la comprensión filosófica del SEM hasta la aplicación práctica de modelos reflexivos, formativos, estructurales, interactivos y predictivos. Complementariamente, se incorpora una perspectiva contemporánea basada en ciencia abierta, que promueve la transparencia metodológica, la reproducibilidad y el uso de software especializado que potencia la calidad y rigor del análisis.

El texto no se limita a la presentación teórica. Por el contrario, ofrece un conjunto de casos de estudio empresariales reales que permiten entender cómo el SEM puede emplearse para resolver problemas estratégicos en áreas como marketing, gestión del talento, cadena de suministro, finanzas y transformación digital. Cada caso está estructurado para maximizar la transferencia del conocimiento, facilitando que investigadores, docentes y profesionales puedan aplicar los conceptos en proyectos propios.

El autor asume un compromiso claro: contribuir al fortalecimiento de la investigación científica en la región y promover un uso responsable, crítico y estratégico del SEM en las ciencias empresariales. Al lector se le ofrece un recurso actualizado, con fundamentos rigurosos y metodologías alineadas con estándares internacionales. Se trata de un libro concebido para acompañar procesos formativos en pregrado y posgrado, así como para apoyar la labor de investigadores consolidados que buscan precisión analítica y profundidad interpretativa.



En perspectiva, este libro cumple un rol doble: amplía la frontera del conocimiento metodológico en ciencias empresariales y, al mismo tiempo, proporciona herramientas de aplicación directa para el análisis y la toma de decisiones organizacionales. Es una contribución significativa a la literatura especializada y un referente para quienes buscan comprender y modelar fenómenos complejos desde una óptica científica, estratégica y orientada a la creación de valor.

Invito al lector a recorrer las páginas que siguen con una actitud reflexiva y crítica. Los capítulos han sido diseñados para fortalecer competencias investigativas, estimular el pensamiento analítico y promover el uso inteligente del SEM como instrumento de investigación avanzada.

Manuel Anchapuri

Perú, febrero de 2026

CAPITULO I

FUNDAMENTOS DEL SEM: FILOSOFÍA Y ALCANCE

Este capítulo establece los cimientos conceptuales del modelado de ecuaciones estructurales (SEM), resaltando su importancia estratégica para la investigación en ciencias empresariales. El enfoque presenta la evolución de las técnicas de primera y segunda generación, así como la transición metodológica desde los modelos basados en covarianza hacia los enfoques predictivos basados en la varianza. Estas aproximaciones han permitido a los investigadores analizar constructos latentes con una precisión cada vez mayor, articulando teoría y evidencia empírica en entornos caracterizados por la complejidad y la incertidumbre del mercado.

La discusión incorpora los fundamentos teóricos que sustentan el SEM y examina las implicaciones gerenciales de su aplicación. Se profundiza en la pertinencia de estas técnicas para la toma de decisiones basada en datos, resaltando su utilidad en la comprensión de fenómenos organizacionales multidimensionales, así como en el diseño de modelos explicativos y predictivos robustos.

1.1 Definición y alcance del modelado de ecuaciones estructurales

El SEM es una familia de técnicas estadísticas multivariantes de segunda generación, extremadamente versátil, que permite a los investigadores especificar, estimar y evaluar modelos de relaciones causales entre variables latentes (constructos) y variables observadas (indicadores).

A diferencia de la regresión múltiple tradicional, que solo considera relaciones entre variables observadas, el SEM integra dos componentes clave en un solo marco analítico:

1. **Modelo de medición (*Outer Model*):** Define la relación entre las variables latentes (no observables directamente, como la "Satisfacción del cliente" o el "Liderazgo transformacional") y sus indicadores observados (ítems del cuestionario). Su objetivo es evaluar la validez y la fiabilidad de las medidas.
2. **Modelo estructural (*Inner Model*):** Especifica las relaciones causales hipotetizadas entre los constructos latentes, permitiendo evaluar la dirección, magnitud y significancia estadística de los vínculos teóricos

La capacidad del SEM para modelar y corregir el error de medición “un problema endémico en la investigación de encuestas”, al tratar las variables latentes como libres de error, le otorga una ventaja considerable en la prueba de hipótesis complejas (Hair et al., 2022).

1.1 De la regresión al SEM (técnicas de 1ra vs. 2da generación)

El análisis estadístico es una herramienta indispensable para los investigadores en el ámbito empresarial y de ciencias sociales. Con el avance del *hardware* y *software* informático, las aplicaciones de los métodos estadísticos se han expandido significativamente, permitiendo el acceso a metodologías más sofisticadas (Hair et al., 2019).

Inicialmente, la investigación se apoyaba en las técnicas de primera generación, como la regresión múltiple, la regresión logística y el análisis de varianza (ANOVA). Si bien estos métodos han sido fundamentales, comparten limitaciones críticas cuando el objetivo es estimar las relaciones entre medidas de conceptos teóricos (Haenlein y Kaplan, 2004). Estas deficiencias son cruciales, ya que las ciencias sociales abordan rutinariamente conceptos no observables como *percepciones*, *actitudes* e *intenciones*.

Los métodos de primera generación presentan tres limitaciones fundamentales (Haenlein y Kaplan, 2004):

1. **Estructura simple:** La presunción de una estructura de modelo simple que no permite el análisis simultáneo de múltiples relaciones de dependencia.
2. **Observabilidad total:** La suposición de que todas las variables son directamente observables, lo cual es incompatible con el trabajo de variable latentes teóricos o latentes.

3. **Ausencia de error de medición:** La asunción de que todas las variables se miden sin error, ignorando el error de escala inherente a la investigación de encuestas.

Para superar estas barreras, los investigadores han recurrido a las técnicas de segunda generación, colectivamente conocidas como modelado de ecuaciones estructurales (SEM). SEM permite modelar y estimar simultáneamente relaciones complejas entre múltiples variables, al tiempo que tiene en cuenta el error de medición en las variables observadas. En consecuencia, este procedimiento proporciona una medida más precisa de los conceptos teóricos relevantes (Cole y Preacher, 2014).

1.2 Anatomía del Modelo

1.1.1 Tipos de variables SEM

En el contexto de un PLS-SEM, las variables se distinguen por su naturaleza de medición (observabilidad) y por su rol causal dentro de la estructura teórica.

Tabla 1

Variables según su nivel de observación

Tipo de Variable	Concepto	Rol y Ejemplo
Variable Observada o Indicador	Variables que se miden directamente en los sujetos de estudio (datos primarios). Son los ítems o preguntas de un cuestionario.	Actúan como representaciones empíricas de los constructos. Ejemplo: Una pregunta específica en una escala Likert.

Tipo de Variable	Concepto	Rol y Ejemplo
Variable Latente (Constructo)	Concepto teórico no observable directamente. Es la característica subyacente que se desea medir, la cual se estima a partir de la varianza común de sus indicadores.	Representa el constructo teórico y se asume que está libre de error aleatorio (ya que el error se modela en el indicador). Ejemplo: La Satisfacción del Cliente, El clima laboral.
Error de Medición ϵ (epsilon)	Componente de error asociado a cada variable observada (indicador).	Representa la varianza única de cada indicador que no es explicada por la variable latente a la que pertenece.

Tabla 2

Variables según su rol causal (Estructura del Modelo)

Tipo de Variable	Concepto	Rol y Características
Variable Exógena	Variable que inicia una cadena causal. Afecta a otras variables dentro del modelo, pero no recibe ningún efecto de ellas.	Actúan como variables independientes. Son los puntos de partida del modelo estructural.
Variable Endógena	Variable que recibe efectos causales de una o más variables (exógenas o endógenas) dentro del modelo.	Actúan como variables dependientes o mediadoras. Toda variable endógena debe estar asociada a un término de error residual.
Error Residual ζ (zeta)	Componente de error asociado a cada variable endógena.	Representa el error de predicción; es decir, la porción de la varianza de la variable endógena que no es explicada por sus variables predictoras en el modelo.
Variable de Agrupación	Variable categórica que define la pertenencia de los sujetos a diferentes	Se utiliza para comparar las relaciones estructurales entre distintos segmentos.

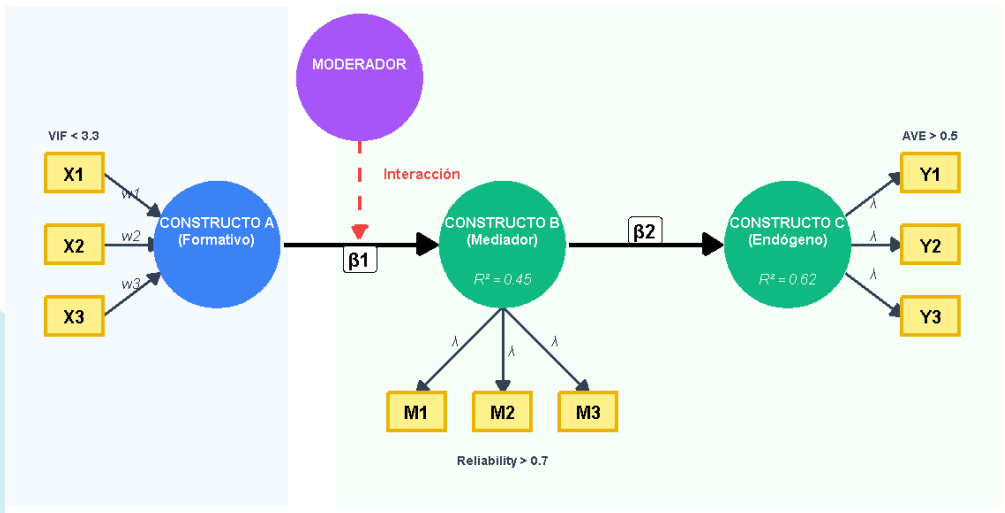
Tipo de Variable	Concepto	Rol y Características
	subpoblaciones o grupos discretos.	(ej., en Análisis Multi-Grupo o MGA). Ejemplo: Género, Nivel Educativo, Ubicación.

1.1.2 Arquitectura y componentes de un modelo SEM

El modelo Path representa el "plano maestro" de la investigación en SEM. Esta visualización permite articular la compleja interacción entre lo abstracto (teoría) y lo empírico (datos). La solidez de este diagrama depende de la correcta alineación de cuatro pilares constitutivos: los constructos, los indicadores observables, las rutas de causalidad y los términos de error. A continuación, la Figura 1 desglosa la anatomía técnica de estos componentes.

Figura 1

Elementos básicos de un modelo SEM



Como se muestra en la Figura 1, el modelo SEM-PLS integra de forma simultánea dos niveles analíticos claramente diferenciados: el modelo de medida y el modelo estructural.

El **modelo de medida (outer model)** permite especificar y evaluar la relación entre los constructos latentes y sus indicadores observables, distinguiendo explícitamente la naturaleza causal de cada tipo de constructo. En primer lugar, los constructos formativos, representados en color azul y ubicados en el lado izquierdo del diagrama, se caracterizan porque los indicadores actúan como causas del constructo latente. En este contexto, la evaluación se centra en la significancia y relevancia de los pesos externos (w), así como en el diagnóstico de multicolinealidad entre indicadores, habitualmente mediante el Factor de Inflación de la Varianza (VIF).

En contraste, los constructos reflectivos, identificados en color verde y situados en la zona central y derecha del modelo, asumen una lógica causal inversa, en la que el constructo latente explica la variación de sus indicadores. La evaluación de estos bloques requiere el análisis de la magnitud de las cargas externas (λ lambda), junto con los criterios de fiabilidad interna y validez convergente, particularmente la fiabilidad compuesta y la varianza media extraída (AVE).

El **modelo estructural (inner model)** representa las relaciones causales hipotetizadas entre los constructos latentes, estimadas a través de los coeficientes de trayectoria (β beta). Este nivel del modelo permite

evaluar la estructura causal subyacente y la coherencia teórica del sistema propuesto. La figura ilustra, además, la capacidad del SEM para incorporar variables mediadoras, que reciben y transmiten efectos causales, así como efectos de moderación, representados mediante términos de interacción, en los cuales una tercera variable condiciona la intensidad o dirección de una relación causal.

Finalmente, los valores de R^2 mostrados en los constructos endógenos expresan la proporción de varianza explicada por el modelo, constituyéndose en un criterio fundamental para evaluar su capacidad explicativa y predictiva, en concordancia con los objetivos analíticos del enfoque SEM-PLS

1.1.3 Especificación del Modelo de Medida: Reflectivo vs. Formativo

Es fundamental para la validez del modelo distinguir la dirección de la causalidad entre el constructo latente y sus indicadores, ya que esto determina las pruebas estadísticas de evaluación. La literatura metodológica identifica dos enfoques opuestos (Hair et al., 2022):

- **Modelos Reflectivos (Modo A):** La dirección de la causalidad va desde el constructo hacia los indicadores (Constructo → Indicadores). Se asume que los indicadores son una "manifestación" o reflejo del constructo subyacente.

Por ejemplo, la "Satisfacción" causa que un cliente puntúe alto en varias preguntas. En este enfoque, se espera que los indicadores estén altamente correlacionados entre sí y sean intercambiables; eliminar uno no altera el significado del constructo.

- **Modelos Formativos (Modo B):** La dirección de la causalidad va desde los indicadores hacia el constructo (Indicadores → Constructo). Aquí, los indicadores "causan" o forman la variable latente. Por ejemplo, el "Nivel Socioeconómico" está formado por la educación, el ingreso y la ocupación; estos no necesariamente correlacionan (se puede tener mucha educación y bajo ingreso) y no son intercambiables. Omitir un indicador en este modelo altera la naturaleza del constructo, perdiendo una parte de su significado (Sarstedt et al., 2019).

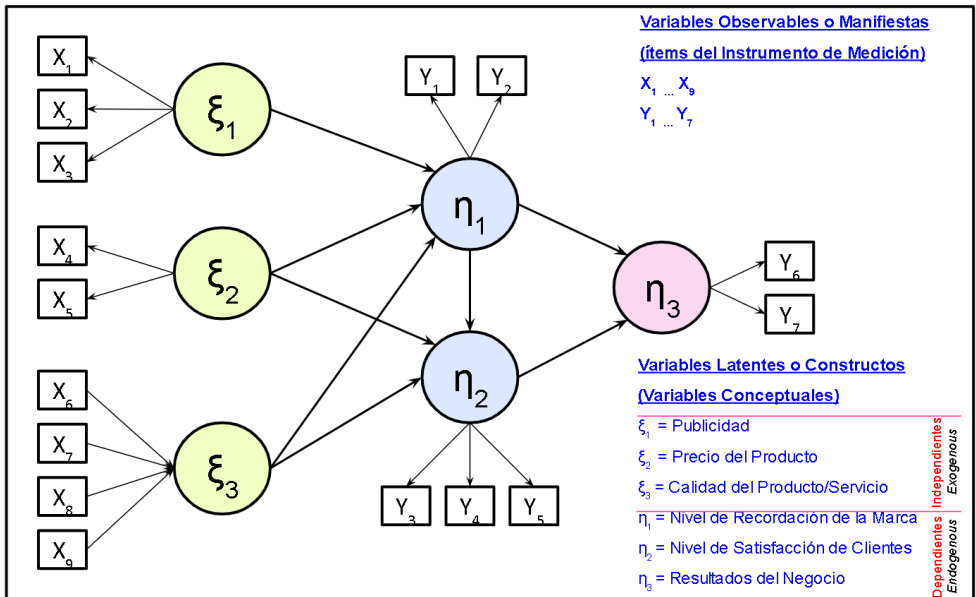
Tabla 3

Elementos gráficos del modelo

Elemento	Representación Gráfica	Definición Teórica
Constructos (Variables Latentes)	Círculos u óvalos	Conceptos teóricos no directamente observables (ej., Satisfacción, Innovación). Pueden ser exógenos (independientes, sin flechas de predicción que les lleguen) o endógenos (dependientes, con flechas que les llegan).

Elemento	Representación Gráfica	Definición Teórica
Variables Medidas (Indicadores)	Rectángulos	Observaciones directamente medidas (datos brutos), también conocidas como variables manifiestas.
Relaciones (Hipótesis)	Flechas de una sola punta	Indican una relación predictiva o causal entre constructos o entre un constructo y sus indicadores. Estas conexiones se fundamentan en la lógica y la teoría estructural.
Términos de Error	Flechas de una sola punta que apuntan al elemento	Representan la varianza que el modelo no puede explicar.

Figura 2
Modelo conceptual SEM




Fuente: Saravia (2024) Universidad del Pacifico PIE

En la Figura 2. Modelo conceptual SEM presenta la estructura teórica propuesta para la investigación, operativizando la revisión de literatura en una red nomológica contrastable. Se visualizan las relaciones de dependencia entre los constructos exógenos (predictores) y endógenos (resultado), estableciendo visualmente las hipótesis (H_1, H_2...) que serán sometidas a prueba estadística mediante el algoritmo PLS

1.1.4 Términos de Error

Los términos de error son esenciales para el rigor estadístico, pero su ubicación depende del tipo de variable:

- Existen para constructos endógenos, ya que su varianza es parcialmente explicada por otros constructos.
- Existen para indicadores medidos de forma reflectiva, pues el constructo no explica el 100% de la varianza del indicador.
- No existen para constructos exógenos o indicadores formativos, ya que estos últimos son las causas o definidores del constructo, y su error se gestiona mediante la colinealidad.

Figura 3*SEM: Modelo Teórico e Hipótesis*

Nota. Modelo teórico simplificado Saravia (2024) Universidad del Pacífico PIE

En la Figura 3. SEM: Modelo Teórico e Hipótesis se aprecia el diagrama formaliza la red de causalidad propuesta, identificando explícitamente las hipótesis de investigación (H_1, H_2, \dots, H_n) que vinculan a los constructos. Esta simplificación del modelo de Saravia (2024) delimita el alcance de la inferencia estadística, especificando la dirección esperada (signo positivo o negativo) de los coeficientes path (beta) que serán estimados en el análisis estructural.

Ejemplos de hipótesis del modelo

- H₁: “La inversión en Publicidad influye de manera positiva y significativa en la Recordación de Marca”
- H₂: “El Precio influye de manera negativa y significativa en la Recordación de Marca”
-
- H₆: “La Recordación de Marca influye significativamente de manera directa, e indirecta con la Satisfacción como variable mediadora, en los Resultados”
- H₇: “La Recordación de Marca influye de manera positiva y significativa en los Resultados”

1.2 Fundamentos teóricos del SEM

La motivación para la adopción generalizada de los modelos SEM en la investigación de negocios es doble: radica en su rigor teórico para la prueba de hipótesis y en su aplicabilidad práctica para la toma de decisiones.

Rigor en la prueba de teorías.

Históricamente, la regresión y el análisis de varianza han limitado la capacidad de los investigadores para testear redes complejas de causalidad. El SEM, en cambio, permite:

- **Modelar múltiples relaciones simultáneamente:** Es posible evaluar cómo un conjunto de variables exógenas influye en múltiples variables endógenas al mismo tiempo. Por ejemplo, cómo la cultura organizacional impacta la innovación y esta, a

su vez, afecta el desempeño financiero, mientras que el liderazgo modera una de estas relaciones (Sarstedt et al., 2020).

- **Análisis de mecanismos (mediación y moderación):** El SEM es la técnica predilecta para desentrañar los procesos causales (*cómo* y *cuándo* ocurren los efectos). La mediación explica los mecanismos intervinientes, mientras que la moderación explica las condiciones contextuales que amplifican o reducen los efectos (Hayes, 2018; Preacher & Hayes, 2008).
- **Gestión del error de medición:** Al especificar las variables latentes, el SEM permite al investigador aislar el error estocástico de las relaciones estructurales, mejorando la fiabilidad de las inferencias causales y la validez de las variables latentes, una necesidad crítica en las ciencias sociales (Bagozzi y Yi, 2012).

1.3 Paradigmas del SEM: Covarianza (CB-SEM) vs. Varianza (PLS-SEM)

En la literatura académica sobre Modelos de Ecuaciones Estructurales (SEM), existe una distinción fundamental que a menudo confunde al investigador novel. El término "SEM" no se refiere a una única técnica estadística, sino que engloba dos escuelas de pensamiento o paradigmas distintos que, aunque comparten el objetivo de analizar relaciones estructurales, difieren radicalmente en sus algoritmos matemáticos, supuestos estadísticos y objetivos de investigación.

Esta dicotomía divide al SEM en dos enfoques principales, cada uno impulsado por una motivación causal distinta: el SEM basado en

Covarianza (CB-SEM) y el SEM basado en Varianza, comúnmente conocido como Mínimos Cuadrados Parciales (PLS-SEM).

1.3.1 El Enfoque Confirmatorio: CB-SEM (Covariance-Based)

El modelado basado en covarianza es el enfoque clásico, popularizado por Jöreskog (1973). Su filosofía se centra en la confirmación y verificación teórica.

- **Lógica Estadística:** Su algoritmo, generalmente de Máxima Verosimilitud (Maximum Likelihood), intenta minimizar la discrepancia entre la matriz de covarianza observada en los datos y la matriz de covarianza teórica implícita en el modelo hipotético. Conceptualmente, considera las variables latentes como factores comunes que explican la covariación entre sus indicadores.
- **Objetivo:** Se utiliza para determinar qué tan bien un modelo teórico *ajusta* a los datos. Es el enfoque ideal cuando el objetivo es confirmar teorías ya establecidas, comparar modelos competitivos o rechazar hipótesis estrictas (Hair et al., 2022).
- **Requisitos:** Exige normalidad multivariante estricta, tamaños de muestra grandes y se adhiere preferentemente a modelos de medición reflexivos.

1.3.2 El Enfoque Predictivo: PLS-SEM (Partial Least Squares)

Por otro lado, el PLS-SEM es un enfoque "causal-predictivo" desarrollado para situaciones donde la teoría es menos madura o el objetivo es la aplicación práctica.

- **Lógica Estadística:** Es una técnica basada en compuestos, lo que implica que las variables latentes se estiman como combinaciones lineales de sus indicadores. A diferencia del CB-SEM, no busca reproducir la matriz de covarianza, sino maximizar la varianza explicada (R^2) de las variables endógenas clave.
- **Objetivo:** Su foco se coloca en el poder predictivo. La validación del modelo se desplaza del ajuste global hacia la capacidad para predecir nuevos datos (out-of-sample predictive power). Es especialmente popular en ciencias empresariales por su capacidad para identificar "drivers" clave de resultados como la lealtad o la rentabilidad.
- **Flexibilidad:** Destaca por su robustez con datos no normales, su capacidad para manejar constructos formativos y su eficacia con tamaños de muestra pequeños o medianos (Sarstedt et al., 2019; Hair et al., 2022).

1.3.3 Marco de Decisión

La elección entre CB-SEM y PLS-SEM no debe ser arbitraria, sino basarse en la naturaleza de la investigación y los datos disponibles. Hair et al. (2019) proponen los siguientes criterios para guiar esta decisión:

Tabla 4

Criterios de Selección Metodológica

Criterio	CB-SEM (Confirmatorio)	PLS-SEM (Predictivo)
Objetivo	Contrastar teorías fuertes, confirmar modelos o evaluar ajuste global.	Predecir constructos clave, desarrollar teoría exploratoria o identificar factores determinantes.
Normalidad de Datos	Requiere normalidad multivariante (curva de campana).	No requiere normalidad (robusto ante datos asimétricos).
Tipo de Medidas	Preferentemente constructos reflexivos.	Maneja constructos reflexivos y formativos indistintamente.
Tamaño de Muestra	Requiere muestras grandes para potencia estadística ($N > 200-300$).	Funciona eficazmente con muestras pequeñas, aunque requiere potencia adecuada.
Complejidad	Limitado a modelos pequeños o medianos (< 50 ítems).	Capaz de gestionar modelos muy complejos (100+ ítems).
Prevalencia	Psicología, Sociología (Ciencias del Comportamiento).	Marketing, Estrategia, Sistemas de Información (Ciencias Empresariales).

Nota. Adaptado de Hair et al. (2019) y Rigdon et al. (2017).

1.4 **Justificación del Enfoque PLS-SEM en ciencias empresariales**

1.4.1 **PLS-SEM en Ciencias Empresariales**

Dado que esta obra se centra en las ciencias empresariales y la toma de decisiones gerenciales, el enfoque metodológico predominante en los capítulos siguientes será el PLS-SEM. Esta decisión se fundamenta en tres realidades de la investigación aplicada a negocios:

1. Los datos empresariales (ventas, satisfacción, percepción) rara vez siguen una distribución normal perfecta.
2. Los modelos de gestión suelen utilizar constructos formativos (ej. el "Éxito Empresarial" está *formado* por la rentabilidad y el crecimiento, no *reflejado* por ellos), los cuales son difíciles de modelar en CB-SEM.
3. El interés del gerente o consultor reside en la predicción (R^2) y la priorización de recursos (IPMA), capacidades nativas del PLS-SEM.

1.4.2 **La importancia de predecir constructos**

El foco de PLS-SEM se coloca en el poder predictivo del modelo. En lugar de replicar la estructura de covarianza, el método busca maximizar la varianza explicada (R^2) en las variables endógenas y evaluar la capacidad del modelo para predecir nuevos

datos. En este sentido, la validación del modelo se desplaza del ajuste a la capacidad predictiva.

Para reflejar este enfoque, Shmueli et al. (2016) han propuesto procedimientos de evaluación más recientes y apropiados, diseñados específicamente para la naturaleza orientada a la predicción de PLS-SEM, como el uso de la capacidad predictiva fuera de la muestra (*out-of-sample predictive power*). Estos nuevos métodos son cruciales para validar los resultados de PLS-SEM.

1.5 Aplicabilidad gerencial y estratégica

La capacidad del SEM para modelar procesos complejos se traduce directamente en inteligencia estratégica para la toma de decisiones:

- **Identificación de palancas estratégicas:** Al cuantificar los coeficientes de sendero, el SEM revela cuáles son las variables exógenas o mediadoras con mayor impacto en un resultado empresarial clave (ej., la lealtad del cliente, la retención de empleados o el desempeño innovador).
- **Validación de modelos de negocio:** Permite validar empíricamente los modelos lógicos de las empresas. Por ejemplo, un modelo que postula que la formación lleva a la competencia técnica y está a la productividad puede ser evaluado por completo en un solo modelo SEM (Shmueli et al., 2019).
- **Análisis de inversión:** Los resultados de SEM guían la asignación de recursos. Si se demuestra que la "calidad del servicio" tiene un

efecto causal significativo y fuerte sobre la "intención de recompra", la gerencia tiene justificación empírica para priorizar la inversión en la mejora de la calidad.

El SEM, en cualquiera de sus variantes (CB-SEM o PLS-SEM), ofrece el marco más completo para testear la plausibilidad de las teorías, garantizando que las conclusiones extraídas del análisis no solo sean estadísticamente sólidas, sino también estratégicamente accionables (Hair et al., 2022). Su dominio es fundamental para la investigación empírica de vanguardia en la disciplina empresarial.

1.6 Entorno informático SEM

Si bien históricamente el análisis de ecuaciones estructurales ha estado dominado por software comercial propietario (como SmartPLS, IBM Amos o LISREL), la tendencia actual en la investigación de alto impacto se inclina hacia la reproducibilidad computacional y el uso de herramientas de código abierto.

Para la implementación efectiva de los conceptos abordados en este texto, se establecen los siguientes estándares en el entorno R:

1.6.1 PLS-SEM (Enfoque basado en la varianza)

- **Paquete Recomendado:** `semInR` (SeminR).
- **Justificación:** Desarrollado en colaboración con los principales teóricos del método (Hair, Sarstedt, Ringle), `semInR` ofrece la sintaxis más intuitiva y robusta para

especificar modelos formativos y reflexivos. A diferencia de las interfaces gráficas rígidas, permite una personalización avanzada de los algoritmos de estimación, bootstrapping y evaluación predictiva (PLSpredict), integrando las métricas más recientes de la literatura metodológica.

1.6.2 CB-SEM (Enfoque basado en la covarianza)

- **Paquete Recomendado:** lavaan (**Latent Variable Analysis**).
- **Justificación:** Es el estándar en R para el modelado confirmatorio. Su capacidad para replicar resultados de software como Mplus o Amos, sumado a su gratuidad y flexibilidad para manejar estimadores robustos (MLR) ante la falta de normalidad, lo convierte en la herramienta indispensable para análisis de invarianza y modelos de medida estrictos.

Tabla 5

Matriz de selección de software en R

Objetivo del Análisis	Enfoque Metodológico	Paquete de R Recomendado	Función Principal
Predicción / Exploración	PLS-SEM (Partial Least Squares)	Library (semnr)	estimate_pls()
Confirmación Teórica	CB-SEM (Covariance-Based)	Library (lavaan)	cfa() o sem()

Objetivo del Análisis	Enfoque Metodológico	Paquete de R Recomendado	Función Principal
Diagramas de Senderos	Visualización Gráfica	Library (semPlot)	semPaths()

En el capítulo se ha establecido los cimientos conceptuales necesarios para comprender el Modelado de Ecuaciones Estructurales (SEM) no solo como una herramienta estadística avanzada, sino como un enfoque metodológico indispensable para la investigación en ciencias empresariales. Hemos transitado desde las limitaciones de las técnicas de primera generación hacia la flexibilidad del SEM, destacando su capacidad única para modelar variables latentes y errores de medición simultáneamente (Hair et al., 2022).

La discusión central ha evidenciado la dicotomía entre el enfoque basado en la covarianza (CB-SEM), orientado a la confirmación teórica, y el enfoque basado en la varianza (PLS-SEM), centrado en la predicción. Para el ámbito de la gestión y los negocios, donde la incertidumbre del mercado exige herramientas capaces de anticipar resultados, el enfoque predictivo del PLS-SEM se revela como la opción más robusta. Al priorizar la maximización de la varianza explicada (R^2) de los constructos dependientes, el investigador puede ofrecer "implicaciones gerenciales" que van más allá de la significancia estadística, aportando valor real a la toma de decisiones estratégicas (Sarstedt et al., 2019).

Finalmente, la integración de estos fundamentos teóricos con un entorno informático moderno, basado en el lenguaje R, prepara el terreno

para la aplicación práctica. El dominio de la sintaxis y la lógica del modelo estructural no es un fin en sí mismo, sino el medio para desenmarañar la complejidad de los fenómenos organizacionales. En los capítulos subsiguientes, trasladaremos estos conceptos abstractos como la distinción entre modelos reflexivos y formativos o la gestión de variables exógenas y endógenas hacia la ejecución técnica directa, permitiendo al lector transformar hipótesis teóricas en modelos empíricos validados.

CAPITULO II

DISEÑO DE INVESTIGACIÓN Y ESTRATEGIA MUESTRAL

Una vez definido el paradigma metodológico y justificada la elección entre el enfoque basado en la covarianza (CB-SEM) o en la varianza (PLS-SEM), tal como se discutió en el capítulo precedente, el investigador se enfrenta a una fase crítica que precede a cualquier recolección de datos: la arquitectura del diseño de investigación. La eficacia del Modelado de Ecuaciones Estructurales (SEM) no reside únicamente en la potencia de sus algoritmos matemáticos, sino en la solidez de las decisiones estratégicas tomadas durante la planificación del estudio (Hair et al., 2022).

En el ámbito de las ciencias empresariales y del comportamiento, los fenómenos rara vez ocurren en condiciones de laboratorio controladas. Por el contrario, la heterogeneidad inherente a los entornos competitivos y organizacionales introduce niveles de "ruido" y variabilidad que exigen diseños muestrales rigurosos (Sarstedt et al., 2022). En este contexto, la selección de la muestra deja de ser un mero trámite logístico para convertirse en un imperativo metodológico. Un diseño muestral deficiente no solo limita la capacidad de generalización estadística, sino que

compromete la estabilidad de las estimaciones de los parámetros y, fundamentalmente, la validez predictiva del modelo (Shmueli et al., 2019).

En consecuencia, este capítulo sostiene que la insuficiencia muestral ya sea por tamaño o por composición no constituye simplemente una limitación técnica subsanable, sino un error metodológico de origen que amenaza la reproducibilidad de la ciencia (Kock y Hadaya, 2018). A lo largo de las siguientes secciones, se desmitificará la premisa de que PLS-SEM es una "bala de plata" para muestras extremadamente pequeñas y se establecerán los protocolos de potencia estadística necesarios para garantizar que los hallazgos empíricos posean la robustez requerida para la toma de decisiones gerenciales.

2.1 Decisión analítica: el marco estratégico

La elección entre el modelado basado en la covarianza (CB-SEM) y el modelado basado en la varianza (PLS-SEM) no constituye una decisión arbitraria ni meramente técnica; es un imperativo estratégico que condiciona todo el diseño muestral. Antes de calcular el tamaño de la muestra, el investigador debe definir la naturaleza epistemológica de su estudio, ya que cada enfoque persigue objetivos diametralmente opuestos (Hair et al., 2019).

Si el objetivo primordial es la confirmación teórica, el diseño debe orientarse hacia el CB-SEM. Este enfoque exige una teoría preexistente sólida y establecida. Su meta analítica es evaluar el ajuste global del modelo; es decir, confirmar si la matriz de covarianza teórica se ajusta perfectamente a la observada en los datos. En consecuencia, el diseño muestral bajo esta ruta debe ser riguroso, satisfaciendo supuestos estrictos de normalidad multivariante y requiriendo tamaños de muestra grandes para garantizar la estabilidad de los parámetros.

Por el contrario, si el objetivo es la predicción y el desarrollo teórico, el diseño debe alinearse con el PLS-SEM. Aquí, la prioridad se desplaza del ajuste global hacia la maximización de la varianza explicada (R^2) de los constructos endógenos y la identificación de sus impulsores clave. En este contexto, el PLS-SEM opera como una *"fuerza de ataque rápida y flexible"*: su algoritmo no depende de la normalidad estricta de los datos y mantiene una robustez notable incluso con muestras más limitadas (Hair et al., 2022).

Esta distinción es crítica para investigadores que operan en mercados emergentes, evalúan tecnologías disruptivas o analizan modelos de negocio innovadores donde la teoría es incipiente. En tales escenarios, donde la incertidumbre es alta y la teoría escasa, la capacidad del PLS-SEM para predecir el rendimiento del fenómeno se convierte en la ventaja metodológica decisiva frente a la rigidez confirmatoria del CB-SEM

Tabla 6

CB-SEM vs, PLS-SEM

Criterio de Decisión	CB-SEM (Basado en Covarianzas)	PLS-SEM (Mínimos Cuadrados Parciales)
Normalidad de los datos	Exigente: Requiere la suposición de distribución normal multivariante.	No Paramétrico: No requiere supuestos de distribución sobre los datos (útil con datos no normales o Likert).
Tamaño de la muestra	Muestras grandes: Se requiere un tamaño de muestra mayor para obtener parámetros estables y un buen ajuste global.	Muestras pequeñas: Robusto con muestras pequeñas (aunque siempre se recomiendan $N > 100$). Sigue la regla del $10 \times$ (10 veces el máximo de flechas apuntando a un constructo).
Complejidad del modelo	Preferido para modelos con pocas variables latentes y muchos indicadores por constructo.	Preferido para modelos complejos con muchas variables latentes y múltiples relaciones estructurales.

Nota. Basado en Hair et al. (2019).

2.2 Teoría del muestreo en SEM: calidad y robustez

Uno de los mitos más persistentes en la investigación con Modelos de Ecuaciones Estructurales es la creencia de que el enfoque PLS-SEM funciona como una "bala de plata" capaz de validar modelos complejos con muestras extremadamente pequeñas. Si bien el algoritmo es robusto ante distribuciones no normales, la literatura metodológica reciente advierte

sobre la "falacia del muestreo inadecuado". Este error metodológico ocurre cuando el investigador interpreta la flexibilidad del PLS-SEM como una licencia para utilizar tamaños muestrales insuficientes, ignorando la complejidad estructural del modelo y la potencia estadística necesaria para detectar efectos significativos (Kline, 2016; Ringle et al., 2022).

Las consecuencias de sucumbir a esta falacia son severas para la integridad del estudio. Una muestra que no cumple con los requisitos mínimos de potencia afecta directamente la estabilidad de los coeficientes path, incrementa la varianza del error y, lo más crítico, compromete la relevancia predictiva del modelo. Como señalan Hair et al. (2021) y Henseler (2023), los resultados derivados de un diseño muestral pobre suelen ser inestables e irreproducibles, anulando la capacidad del modelo para ofrecer inferencias válidas sobre la población objetivo.


Finalmente, es imperativo comprender que la robustez del muestreo trasciende la mera cantidad de observaciones (N). La calidad del dato exige una evaluación integral que incluya la ausencia de sesgos de no respuesta, la consistencia conceptual del marco muestral y la representatividad genuina del grupo de análisis. Incluso con un N elevado, si la recolección de datos carece de rigor en estos factores complementarios, la capacidad de generalización y predicción del modelo se verá fracturada (Sarstedt et al., 2022; Sarstedt y Henseler, 2023)

2.3 Potencia estadística (1-beta) y decisiones metodológicas

Más allá de cumplir con un número arbitrario de encuestas, el diseño muestral debe obedecer a la lógica de la potencia estadística (1-beta). En términos formales, la potencia se define como la probabilidad condicional de rechazar la hipótesis nula (H_0) cuando esta es realmente falsa; es decir, la capacidad del test para detectar un efecto significativo cuando dicho efecto existe en la realidad (Cohen, 1992).

2.1.1 El Estándar de Oro: El umbral del 80%

La comunidad científica ha adoptado universalmente el criterio propuesto por Jacob Cohen, estableciendo una potencia mínima del 80% (0.80) como el estándar de rigor. Esto implica que el investigador acepta un riesgo máximo del 20% ($\beta = 0.20$) de cometer un **Error Tipo II** (falsos negativos), o lo que es lo mismo, fallar en detectar una relación que verdaderamente existe. Operar por debajo de este umbral convierte la investigación en un ejercicio de azar, donde la ausencia de significancia estadística puede deberse simplemente a la falta de sensibilidad de la muestra y no a la ausencia del fenómeno.

Figura 4*Interacción entre Errores Estadísticos y Potencia (1-beta)*

La gráfica ilustra el dilema fundamental de la inferencia estadística en SEM: la capacidad de distinguir entre el "ruido" (Hipótesis Nula, H_0) y la "señal" verdadera (Hipótesis Alternativa, H_1).

1. **El Umbral de Decisión (Línea Punteada Vertical):** Representa el valor crítico (generalmente asociado a un $\alpha = 0.05$). Cualquier estadístico t o z que caiga a la derecha de esta línea se considera "significativo".
2. **Zona Roja (alpha - Error Tipo I):** Es la probabilidad de "Falso Positivo". Ocurre cuando el investigador rechaza la hipótesis nula (afirma que hay un efecto) cuando en realidad no existe. Este error se controla fijando el nivel de significancia (usualmente al 5%).

3. **Zona Azul (beta - Error Tipo II):** Es la probabilidad de "Falso Negativo". Representa el riesgo de que el efecto exista realmente (estamos bajo la curva sólida H_1), pero nuestros datos no sean lo suficientemente contundentes para cruzar el umbral crítico. Este es el riesgo principal de usar muestras pequeñas en PLS-SEM: la zona azul crece y oscurece la verdad.
4. **Zona Verde (Potencia Estadística, 1-beta):** Es la probabilidad de éxito. Representa el área bajo la curva alternativa que supera el umbral crítico. Un diseño muestral robusto busca maximizar esta área verde hasta alcanzar, al menos, el 80%.

Para aumentar el área verde (Potencia) y reducir la azul (Error II), el investigador tiene dos caminos matemáticos: aumentar la magnitud del efecto (separar las curvas) o, lo que es más controlable, aumentar el tamaño de la muestra para "adelgazar" las curvas (reducir el error estándar), minimizando así el solapamiento entre las hipótesis.

2.1.2 Implicaciones Críticas para PLS-SEM

La potencia cobra una relevancia crítica en el entorno PLS-SEM, donde frecuentemente se modelan fenómenos de ciencias del comportamiento con tamaños del efecto (f^2) moderados o pequeños. Existe una relación inversamente proporcional que el investigador debe gestionar: a medida que aumenta la complejidad del modelo (número de predictores) y disminuye la magnitud del efecto esperado, la potencia estadística cae drásticamente si el tamaño muestral (n) se mantiene constante.

Si el diseño muestral es débil, el modelo PLS-SEM perderá su "agudeza visual", volviéndose incapaz de identificar relaciones

estructurales sutiles, pero teóricamente relevantes. Por ello, la recomendación práctica antes de iniciar el trabajo de campo es realizar un análisis de sensibilidad ($G^*Power > Sensitivity Analysis$). Este procedimiento permite calcular cuál es el tamaño del efecto mínimo que la muestra disponible será capaz de detectar con una potencia del 80%, ajustando así las expectativas teóricas a la realidad empírica del estudio (Hair et al., 2021)

2.4 Métodos de estimación del tamaño muestral

La determinación del tamaño de la muestra en PLS-SEM no es un procedimiento monolítico, sino una decisión jerárquica que depende del nivel de rigor exigido por la investigación. La literatura actual permite clasificar las estrategias de estimación en tres niveles de complejidad ascendente:

2.4.1 Nivel 1: Aproximación Heurística

(La regla de las "10 veces")

Históricamente, este ha sido el método más citado debido a su simplicidad operativa. Propuesto originalmente por Barclay et al. (1995), este criterio establece que el tamaño mínimo de la muestra debe ser 10 veces el número máximo de flechas estructurales dirigidas a un constructo latente en el modelo (ya sean indicadores formativos o rutas estructurales).

- **Advertencia Metodológica:** Aunque útil para estimaciones preliminares rápidas, la literatura contemporánea (Hair et al., 2022) advierte que este método carece de precisión estadística. No se recomienda como justificación única en investigaciones de alto impacto o tesis doctorales, ya que tiende a subestimar los requerimientos muestrales en modelos complejos, ignorando la potencia estadística y el tamaño del efecto.

2.4.2 Nivel 2: Análisis de Potencia a Priori

(El Estándar Áureo)

Para cumplir con los estándares de las revistas indexadas (Q1/Q2), la estimación debe basarse en el análisis de potencia estadística. Este enfoque utiliza algoritmos, disponibles en software como G*Power, para calcular el N exacto en función de tres parámetros críticos (Cohen, 1992; Faul et al., 2009):

1. **Potencia Estadística (1-beta):** Generalmente fijada en 0.80 (80%), asegurando una alta probabilidad de detectar efectos existentes.
2. **Nivel de Significación (alpha):** Típicamente 0.05, definiendo el umbral de error tipo I tolerado.

3. **Tamaño del Efecto (f^2):** La magnitud mínima de la relación que el investigador espera detectar (pequeño, mediano o grande).

Determinación del Tamaño del Efecto Esperado (f^2)

A diferencia del nivel de significancia ($\alpha = 0.05$) y la potencia ($1 - \beta = 0.80$), que son convenciones estadísticas fijas, el tamaño del efecto (f^2) es un parámetro que depende de la naturaleza del fenómeno estudiado. Este valor representa la magnitud de la relación que el investigador espera encontrar entre las variables.

Para la estimación *a priori* del tamaño muestral, Cohen (1992) establece tres umbrales de referencia ampliamente aceptados en las ciencias del comportamiento:

- **Efecto Pequeño ($f^2 = 0.02$):** Requiere muestras grandes para ser detectado. Es común en estudios donde múltiples factores influyen levemente en la variable dependiente.
- **Efecto Mediano ($f^2 = 0.15$):** Estándar recomendado cuando no existen antecedentes previos. Representa una influencia visible a "simple vista" estadística.
- **Efecto Grande ($f^2 = 0.35$):** Implica una relación muy fuerte y evidente, detectable con muestras reducidas.

Nota: En ausencia de estudios previos o meta-análisis que sugieran un valor específico, se recomienda utilizar el criterio de **Efecto Mediano ($f^2 = 0.15$)** como punto de partida conservador para el

cálculo en G*Power. Asumir un efecto grande sin justificación puede derivar en una subestimación peligrosa del tamaño muestral necesario.

2.4.3 Nivel 3: Simulaciones y criterios de complejidad

En el nivel más alto de sofisticación, especialmente necesario cuando los supuestos distribucionales son severamente violados o la arquitectura del modelo es inusual, se recurre a métodos avanzados:

- **Simulaciones Monte Carlo:** Permiten evaluar la estabilidad de los parámetros bajo miles de escenarios hipotéticos de remuestreo, ofreciendo la justificación más robusta posible (Hair et al., 2021).
- **Criterios de Estructura del Modelo:** Enfoques como el de Marcoulides y Saunders (2006) proponen tablas de referencia que ajustan el tamaño muestral necesario basándose en la complejidad conceptual (número de constructos y relaciones) y la comunalidad de las variables, siendo vitales para modelos de gran escala.

Tabla 7*Comparativa de métodos en PLS-SEM*

Método de Estimación	Ventaja Principal	Desventaja Principal
Regla de las 10 veces (Heurística)	Simplicidad operativa: Permite un cálculo inmediato sin necesidad de software externo. Ideal para verificaciones rápidas.	Falta de precisión: No considera la potencia estadística ni el tamaño del efecto. Es frecuentemente rechazada en revistas de alto impacto.
Análisis de Potencia (GPower / Cohen)*	Rigor Científico: Es el estándar actual. Garantiza el control sobre los errores Tipo I y II, asegurando la validez estadística.	Dependencia de parámetros: Requiere que el investigador estime a priori el tamaño del efecto esperado (f^2), lo cual puede ser difícil sin estudios previos.
Simulaciones Monte Carlo (Complejidad del modelo)	Máxima Robustez: Evalúa la estabilidad de los parámetros bajo miles de escenarios, ideal para datos no normales o modelos muy complejos.	Alta Exigencia Técnica: Requiere mayor capacidad computacional y un conocimiento avanzado de programación o configuración de software.

Nota. Elaboración basada en Hair et al. (2022) y Cohen (1992).

Escenarios de Muestra Fija: El Análisis de Sensibilidad (Post-hoc)

Frecuentemente, el investigador opera bajo restricciones logísticas o presupuestarias que hacen que el tamaño de la muestra sea inelástico (por ejemplo, al trabajar con una base de datos histórica cerrada o una población finita muy reducida). En estos casos, donde no es factible aumentar el N para alcanzar la potencia deseada, el cálculo *a priori* pierde su utilidad práctica.

La alternativa metodológica rigurosa es ejecutar un **Análisis de Sensibilidad** (*Sensitivity Analysis*). Esta función, disponible en software como G*Power (*Compute required effect size given alpha, power, and N*), invierte la lógica de la ecuación: en lugar de preguntar cuántos sujetos se necesitan, el investigador introduce el N fijo disponible para determinar cuál es el tamaño del efecto mínimo (f^2) que el modelo será capaz de detectar con fiabilidad.

- **Criterio de Decisión:** Si el análisis revela que la muestra disponible solo tiene potencia para detectar efectos "grandes" ($f^2 > 0.35$), el investigador debe reconocer explícitamente esta limitación. Esto implica advertir que las relaciones causales sutiles o moderadas podrían existir en la realidad, pero pasarán desapercibidas en el estudio (riesgo de Error Tipo II) debido a la falta de sensibilidad de los datos (Faul et al., 2009).

2.5 Diseño para la investigación exploratoria y predictiva

La elección del diseño muestral y analítico culmina con la alineación entre la técnica y el estado de madurez de la teoría. Históricamente, Herman Wold (1985), el creador del método PLS, enfatizó que la utilidad primordial de este enfoque reside en su capacidad para el "modelado suave" (*soft modeling*), permitiendo al investigador evaluar mejoras tentativas en la estructura del modelo como la adición o supresión de variables latentes de manera ágil y orientada a la maximización de la capacidad predictiva.

En el contexto contemporáneo de las ciencias empresariales, el diseño basado en PLS-SEM se establece como el estándar preferente para el desarrollo teórico por tres razones metodológicas fundamentales:

1. **Robustez ante la No-Normalidad de los Datos:** La realidad empírica de los negocios rara vez se ajusta a la curva de campana ideal. El uso extensivo de escalas Likert y la asimetría natural de datos financieros o comportamentales violan frecuentemente el supuesto de normalidad multivariante exigido por el CB-SEM. El diseño PLS-SEM gestiona estas distribuciones con una robustez superior, evitando sesgos en la estimación de parámetros sin requerir transformaciones de datos artificiales (Hair et al., 2022).
2. **Focalización en la Relevancia Gerencial (R^2):** Mientras que otros enfoques priorizan el ajuste global (*model fit*), el diseño PLS-SEM responde a la pregunta pragmática de la gestión estratégica: "*¿Qué constructos poseen el mayor poder para predecir el rendimiento, la satisfacción o la lealtad?*". Al centrarse en maximizar el coeficiente de determinación (R^2) de las variables endógenas, el método alinea el rigor estadístico con la utilidad práctica para la toma de decisiones.
3. **Flexibilidad en el Continuo Exploratorio-Confirmatorio:** Es crucial superar la dicotomía rígida que encasilla al PLS-SEM únicamente como una herramienta exploratoria. Si bien es ideal para teorías en desarrollo, Hair et al. (2017) clarifican que este enfoque

es igualmente válido para diseños confirmatorios cuando el objetivo final de la investigación es la **predicción** de constructos clave. Esta dualidad permite al investigador transitar desde la generación de hipótesis hasta su validación predictiva dentro de un mismo marco metodológico unificado.

Con un diseño muestral fundamentado en la potencia estadística y una clara justificación del enfoque predictivo, el investigador ha establecido los cimientos sólidos para la fase de ejecución. En el siguiente capítulo, abordaremos el Protocolo de Evaluación, detallando los criterios de calidad que transforman estos datos en evidencia científica válida

"La integridad del análisis que sigue depende de este cimiento: solo una muestra con la potencia adecuada faculta a las métricas del Capítulo III para discriminar, sin ambigüedad, entre la causalidad verdadera y el ruido estadístico."

Referencias

- Barclay, D., Higgins, C., y Thompson, R. (1995). The partial least squares (PLS) approach to causal modeling: Personal computer adoption and use as an illustration. *Technology Studies*, 2(2), 285–309.
- Cohen, J. (1992). A power primer. *Psychological Bulletin*, 112(1), 155–159. <https://doi.org/10.1037/0033-2909.112.1.155>
- Faul, F., Erdfelder, E., Buchner, A., y Lang, A.-G. (2009). Statistical power analyses using G*Power 3.1: Tests for correlation and regression analyses. *Behavior Research Methods*, 41(4), 1149–1160. <https://doi.org/10.3758/BRM.41.4.1149>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., y Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (3^a ed.). Sage.
- Hair, J. F., Matthews, L. M., Matthews, R. L., y Sarstedt, M. (2017). PLS-SEM or CB-SEM: Updated guidelines on which method to use. *International Journal of Multivariate Data Analysis*, 1(2), 107–123. <https://doi.org/10.1504/IJMDA.2017.087624>
- Hair, J. F., Risher, J. J., Sarstedt, M., y Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Henseler, J. (2023). *Composite-based structural equation modeling: Analyzing latent and emergent variables*. Guilford Press.

- Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4^a ed.). Guilford Press.
- Kock, N., y 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://doi.org/10.1111/isj.12131>
- Marcoulides, G. A., y Saunders, C. (2006). PLS: A silver bullet? *MIS Quarterly*, 30(2), III–IX. <https://doi.org/10.2307/25148727>
- Ringle, C. M., Sarstedt, M., Sinkovics, N., y Sinkovics, R. R. (2022). A perspective on using partial least squares structural equation modeling in data articles. *Data in Brief*, 48, 109074.
- Sarstedt, M., Hair, J. F., Pick, M., Lienggaard, B. D., Radomir, L., y Ringle, C. M. (2022). Progress in partial least squares structural equation modeling use in marketing research in the last decade. *Psychology & Marketing*, 39(5), 1035–1064. <https://doi.org/10.1002/mar.21640>
- Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J. H., Thiele, K. O., y Ringle, C. M. (2019). Prediction-oriented model evaluation in PLS-SEM: Guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322–2347. <https://doi.org/10.1108/EJM-02-2019-0189>
- Wold, H. (1985). Partial least squares. En S. Kotz y N. L. Johnson (Eds.), *Encyclopedia of statistical sciences* (Vol. 6, pp. 581–591). Wiley.

CAPITULO III

PROTOCOLO DE EVALUACIÓN Y REPORTE DE RESULTADOS

Tras haber definido en el capítulo anterior la estrategia de muestreo y garantizado la potencia estadística necesaria para la detección de efectos, la investigación entra en su fase analítica decisiva: la validación empírica. Sin embargo, tener datos recolectados no es sinónimo de tener evidencia científica. Los datos son, en esta etapa, materia prima que debe someterse a un riguroso control de calidad antes de poder extraer conclusiones gerenciales o teóricas.

Este capítulo detalla el protocolo sistemático de evaluación en PLS-SEM. A diferencia de las técnicas de primera generación (como la regresión múltiple), donde a menudo se asume que las mediciones son perfectas, el SEM exige un escrutinio dual: primero debemos demostrar que nuestros instrumentos de medición funcionan (fiabilidad y validez) y, solo entonces, podremos evaluar si nuestras hipótesis teóricas son ciertas (predicción y causalidad). A lo largo de las siguientes páginas, desglosaremos este proceso en una hoja de ruta estandarizada que transformará los datos crudos en hallazgos robustos y publicables.

3.1 Fundamentos metodológicos de la validación

La validación en el Modelado de Ecuaciones Estructurales (SEM) trasciende la mera formalidad de "cumplir con los índices". Se trata de un proceso sistemático de filtrado diseñado para proteger al investigador de cometer errores de inferencia. Su función es garantizar que los constructos abstractos (como "Lealtad" o "Innovación") y sus relaciones causales sean teóricamente coherentes y empíricamente robustos.


Desde una perspectiva epistemológica, este proceso articula los principios de la teoría de la medición con la evaluación predictiva. El objetivo final es asegurar que las conclusiones del estudio no sean artefactos estadísticos, sino insumos confiables para la toma de decisiones estratégicas en entornos de incertidumbre (Hair et al., 2021).

3.1.1 Los dos niveles de teoría en SEM

Para operacionalizar este análisis sin perderse en la complejidad matemática, es imperativo distinguir que un modelo SEM no es una entidad monolítica, sino la fusión de dos niveles de teoría que operan simultáneamente. Como se detalla en la siguiente Tabla, cada nivel cumple una función metodológica distinta y ataca una parte diferente del modelo gráfico.

Figura 5

*Arquitectura dual del modelo SEM:
Integración de la teoría de la medición y la teoría estructural)*



La Figura 5 desglosa visualmente la complejidad del modelado SEM en tres componentes analíticos diferenciados, facilitando la comprensión de la "Secuencia de Dos Pasos" descrita en la sección anterior:

1. El "Cinturón" de Medición (Zonas Grises Laterales):

Los paneles laterales, etiquetados como Modelo Externo, representan la Teoría de la Medición¹. Aquí se observa la dirección de las flechas finas partiendo desde los constructos (círculos) hacia los indicadores (rectángulos). Esta dirección certifica que estamos ante un modelo reflexivo: se asume teóricamente que la variable latente (X o Y) es la causa que genera los valores en los ítems observados (x₁...x₃). La validación de estas zonas grises (Paso 1) es el prerrequisito de calidad de datos.

2. El "Núcleo" Estructural (Zona Azul Central):

El panel central, destacado en azul, contiene la Teoría Estructural². Representa la hipótesis del investigador sobre cómo funciona la realidad. Nótese que la flecha que conecta X con Y es visualmente más gruesa y destacada. Esto simboliza que, aunque el modelo requiere de todas las partes para funcionar, el objetivo

epistemológico final es evaluar la fuerza y significancia de esta relación causal central (Paso 2).

3. Jerarquía del Análisis:

La disposición gráfica refuerza que no es posible acceder al "núcleo" (evaluar si X influye en Y) sin atravesar primero el "cinturón" de medición. Si los indicadores en las zonas grises no capturan adecuadamente los constructos (bajas cargas o falta de fiabilidad), la flecha central azul carecerá de validez empírica, independientemente de lo que indiquen los cálculos matemáticos.

Tabla 8

Dimensiones teóricas y componentes del modelo SEM

Tipo de Teoría	Componente del Modelo	Función Metodológica (El "Qué" hace)
Teoría de Medición	Modelo Externo (Outer Model)	Especifica cómo los indicadores observados (preguntas de la encuesta) materializan un concepto abstracto. Define las reglas de correspondencia entre la realidad empírica y la teoría latente (reflexiva o formativa).
Teoría Estructural	Modelo Interno (Inner Model)	Especifica la red de relaciones causales entre los constructos latentes. Determina las hipótesis predictivas (las flechas entre círculos) y la arquitectura del fenómeno estudiado.

Nota. Adaptado de Hair et al. (2019) y Gregory (1980).

3.1.2 El Principio de la "Secuencia de Dos Pasos"

Esta distinción entre medición y estructura fundamenta la regla de oro de la validación en SEM: la "Secuencia de Dos Pasos". Este principio, inquebrantable en la literatura contemporánea, establece una jerarquía lógica en el análisis:

"Ningún modelo estructural (relaciones entre variables) puede ser interpretado si previamente no se ha demostrado que sus instrumentos de medida son válidos y confiables" (Hair et al., 2021).

La lógica didáctica detrás de este principio es análoga a la calibración de instrumentos en ingeniería: no tiene sentido medir la velocidad de un vehículo si el velocímetro está roto. En SEM, intentar analizar hipótesis causales (Modelo Interno) con mediciones deficientes (Modelo Externo) carece de sentido epistemológico. Si los datos que alimentan el modelo son "ruido", cualquier relación causal encontrada será espuria, conduciendo a lo que se conoce como falacias estadísticas.

Por tanto, el protocolo de validación que seguiremos en este capítulo respeta estrictamente este orden:

1. **Paso 1:** Validar el instrumento de medición (¿Medimos bien lo que decimos medir?).
2. **Paso 2:** Examinar las relaciones estructurales (¿Influye la variable A en la variable B?).

3.2 **Paso 1: Validación del modelo de medida (Outer Model)**

El primer filtro analítico del protocolo consiste en evaluar la correspondencia métrica entre el constructo latente y sus indicadores observables. Dado que la inmensa mayoría de las escalas en ciencias del comportamiento son de naturaleza reflexiva (donde el constructo "causa"

las respuestas en los ítems), esta sección detalla los criterios específicos para este tipo de medición.

Para los modelos reflexivos, la validación exige el cumplimiento estricto y secuencial de cuatro criterios estadísticos jerárquicos:

⚠ Nota de Advertencia Metodológica: Alcance del Protocolo

Es crucial distinguir la naturaleza de su modelo antes de aplicar los siguientes criterios. Las métricas que se detallan a continuación (Cargas, Alpha de Cronbach, AVE) son válidas exclusivamente para modelos de medida reflexivos (Modo A).

Si su investigación incorpora constructos formativos (donde los indicadores causan o forman la variable latente, ej. Índice de Nivel Socioeconómico), aplicar estas métricas constituye un error metodológico grave. Los modelos formativos requieren un protocolo de validación totalmente distinto, centrado en la evaluación de la colinealidad (**VIF**) de los indicadores y la significancia estadística de los pesos externos (*outer weights*), en lugar de las cargas factoriales (Hair et al., 2021).

3.2.1 Confiabilidad del Indicador

Este análisis examina la carga factorial externa (*outer loading*) de cada ítem individual para determinar si el indicador realmente pertenece al constructo.

- **Criterio de Magnitud:** El estándar metodológico establece que las cargas deben ser superiores a 0.7081. Este umbral garantiza que el constructo explica más del 50% de la varianza del indicador ($0.708^2 > 0.50$), asegurando que la varianza compartida supera a la varianza del error. Cargas inferiores sugieren que el ítem introduce más "ruido" que información sustantiva.

Nota de Rigor: Significancia Estadística

No basta con observar la magnitud de la carga; es imperativo confirmar que esta no sea producto del azar. Además de superar el umbral de 0.708, cada carga debe ser estadísticamente significativa.

Esto se verifica mediante el procedimiento de Bootstrapping. El investigador debe comprobar que el estadístico t asociado a cada carga sea mayor a 1.96 (para un nivel de confianza del 95%). Si una carga es alta en valor absoluto pero su $t < 1.96$, el indicador no es confiable y debe ser eliminado.

3.2.2 Consistencia Interna

Este criterio evalúa si el conjunto de indicadores que componen un constructo mide la misma magnitud teórica de manera

homogénea. Para su verificación, se utilizan dos coeficientes complementarios:

- **Alpha de Cronbach:** Actúa como el límite inferior conservador de la fiabilidad, asumiendo (a menudo erróneamente) que todos los indicadores tienen cargas iguales.
- **Fiabilidad Compuesta (*Composite Reliability*):** Representa el límite superior y es una medida más precisa en PLS-SEM al considerar las cargas individuales de cada ítem.

En ambos casos, valores situados entre 0.70 y 0.95 se consideran satisfactorios. Valores superiores a 0.95 pueden indicar redundancia de ítems (semánticamente idénticos), lo cual no es deseable.

3.2.3 Validez Convergente

Se determina mediante la Varianza Extraída Media (AVE). Este indicador global del constructo debe ser superior a 0.50. Un valor por encima de este umbral garantiza que, en promedio, el constructo latente es capaz de explicar más de la mitad de la varianza de sus propios indicadores, convergiendo así en una medición sólida y representativa del fenómeno estudiado.

3.2.4 Validez discriminante

Es la prueba crítica para demostrar que cada constructo es empíricamente distinto de los demás y no está capturando fenómenos solapados (validez divergente). Aunque históricamente se utilizó el criterio de Fornell-Larcker, la literatura contemporánea (Henseler et al., 2015; Hair et al., 2021) ha demostrado su baja sensibilidad. Por ello, se recomienda priorizar la ratio **HTMT** (*Heterotrait-Monotrait Ratio*).

- **Criterio de decisión:** Valores de HTMT inferiores a 0.85 (o 0.90 en conceptos teóricamente similares) confirman que existe una distinción real entre las variables latentes. Si el HTMT supera el umbral de 1.0, existe una falta total de validez discriminante.

3.3 Paso 2: Validación del Modelo Estructural (Inner Model)

Una vez certificada la fiabilidad y validez de los instrumentos de medida (Paso 1), el investigador tiene "luz verde" metodológica para proceder a la evaluación del modelo estructural. En esta fase, el foco del análisis cambia radicalmente: el objetivo ya no es verificar la calidad de los datos, sino determinar la **significancia causal** de las relaciones teóricas y la **capacidad predictiva** del modelo propuesto.

La evaluación del modelo interno se estructura en tres dimensiones analíticas fundamentales:

3.3.1 Evaluación de la Colinealidad (VIF)

El primer paso crítico en el modelo estructural es examinar la colinealidad lateral. Este fenómeno ocurre cuando dos o más variables latentes independientes (predictores) están altamente correlacionadas entre sí, lo que dificulta que el algoritmo estime con precisión la influencia única de cada una sobre la variable dependiente. La presencia de alta colinealidad puede distorsionar los coeficientes de ruta, volviéndolos inestables o incluso invirtiendo su signo contraintuitivamente.

Para diagnosticar este problema, se utiliza el **Factor de Inflación de la Varianza (VIF)**. Se debe examinar el VIF de cada conjunto de constructos predictores para cada variable endógena.

- **Criterio de Decisión:**
 - **VIF < 3.0 (Ideal):** Indica que no hay problemas de colinealidad. Es el estándar de rigor actual recomendado por Hair et al. (2021).
 - **VIF < 5.0 (Tolerable):** Se considera aceptable en estudios exploratorios o con teorías menos maduras, aunque implica cierto grado de solapamiento informativo.
 - **VIF \geq 5.0 (Crítico):** Indica problemas severos de colinealidad. El investigador debe tomar medidas correctivas, como eliminar uno de los constructos redundantes o fusionarlos en un constructo de orden superior.

Una vez descartada la colinealidad ($VIF < 3$ o < 5), se puede proceder con confianza a la evaluación de las relaciones causales.

3.3.2 Evaluación de las Relaciones Causales

(Path Coefficients)

Los coeficientes de ruta o *path coefficients* (beta) representan las hipótesis centrales del estudio; indican la fuerza y la dirección de la relación entre las variables latentes. Dado que PLS-SEM es una técnica no paramétrica que no asume normalidad en la distribución de los datos, la significancia estadística de estos coeficientes no puede determinarse mediante las pruebas t tradicionales.

En su lugar, se utiliza el procedimiento de Bootstrapping (remuestreo). Esta técnica re-muestra los datos originales para estimar el error estándar de los coeficientes.

- **Configuración Técnica:** Para garantizar la estabilidad de los resultados, se recomienda configurar el software analítico (ej. SmartPLS, R-semPLS, ADANCO o WarpPLS) con un mínimo de 5,000 submuestras (idealmente 10,000). Una configuración con menos submuestras podría generar valores p imprecisos.

- **Criterio de decisión:** A partir del remuestreo, se analizan los Intervalos de Confianza (*Bias-Corrected Confidence Intervals*). Si el intervalo para un coeficiente beta no incluye el cero (ej. [0.15; 0.45]), se concluye que el efecto es estadísticamente significativo con un 95% de confianza (Preacher y Hayes, 2008)

3.3.3 Coeficiente de Determinación (R²)

Mientras que la significancia nos dice si un efecto existe, estos dos indicadores nos dicen "cuánto importa" ese efecto.

- **Coeficiente de Determinación (R²):** Evalúa el poder explicativo del modelo (*in-sample prediction*). Representa la cantidad de varianza de la variable endógena (dependiente) que es explicada por sus predictores. En investigaciones de marketing y gestión, los valores de referencia suelen interpretarse así (Hair et al., 2021):
 - **0.75:** Poder explicativo **Sustancial**.
 - **0.50:** Poder explicativo **Moderado**.
 - **0.25:** Poder explicativo **Débil**.

3.3.4 Tamaño del Efecto (f²)

Es una medida de sensibilidad que aísla la contribución específica de cada predictor individual. Responde a la pregunta gerencial: "*Si elimino esta variable del modelo, ¿cuánto pierdo en capacidad de predicción?*". Permite identificar qué constructos son

los impulsores clave del fenómeno y cuáles tienen un impacto meramente marginal.

3.3.5 Relevancia Predictiva (Q^2)

Finalmente, se evalúa la capacidad del modelo para predecir datos que no fueron utilizados en la estimación inicial (*out-of-sample prediction*). Históricamente, este análisis se realizaba mediante el procedimiento de Blindfolding, que calcula el valor Q^2 de Stone-Geisser omitiendo datos sistemáticamente.

- **Criterio tradicional:** Un valor de $Q^2 > 0$ indica que el modelo tiene relevancia predictiva.

Sin embargo, la literatura metodológica más reciente (Shmueli et al., 2019) señala que el *Blindfolding* no es una medida de predicción pura, ya que reutiliza los datos de la muestra. Por ello, se recomienda encarecidamente utilizar el algoritmo **PLSpredict**.

- **La ventaja de PLSpredict:** Esta técnica divide la muestra en subconjuntos de entrenamiento y prueba (*k-fold cross-validation*), permitiendo evaluar si el modelo SEM predice mejor el comportamiento de los nuevos casos que un modelo lineal ingenuo (LM).
- **Criterio de decisión actualizado:** Si los errores de predicción del modelo PLS (RMSE o MAE) son menores

que los del modelo lineal (LM), el modelo posee un poder predictivo alto y robusto.

3.4 Consideraciones sobre el ajuste global y la predicción.

Una de las áreas de mayor controversia y evolución en la literatura metodológica reciente reside en el concepto de "Ajuste del Modelo" (*Model Fit*). Históricamente, los investigadores formados en la tradición del CB-SEM (basado en covarianzas, como AMOS o LISREL) han buscado validar sus modelos mediante índices globales como el CFI, RMSEA o χ^2 . Sin embargo, trasladar esta lógica de forma automática al entorno de PLS-SEM constituye un error conceptual que puede derivar en el rechazo injustificado de modelos predictivos válidos.

A diferencia del CB-SEM, cuyo algoritmo busca minimizar la discrepancia entre la matriz de covarianza teórica y la observada, el PLS-SEM es un enfoque causal-predictivo que maximiza la varianza explicada de los constructos endógenos. Esta diferencia fundamental ha llevado a algunos críticos a sostener erróneamente que PLS-SEM es menos riguroso para la confirmación de teorías (Westland, 2015). No obstante, la realidad metodológica es que PLS-SEM prioriza la predicción sobre el ajuste global (Shmueli et al., 2019).

Siguiendo las directrices actualizadas de Hair et al. (2021) y Rigdon (2012), evaluar un modelo PLS exclusivamente bajo la óptica de las métricas de ajuste tradicionales es inadecuado por tres razones estructurales:

3.4.1 Fundamento algorítmico (Incongruencia Matemática)

El algoritmo PLS se basa en regresiones de mínimos cuadrados ordinarios (OLS) diseñadas para la predicción, no para la optimización del ajuste global. Las métricas basadas en χ^2 asumen que el objetivo es reproducir perfectamente la matriz de covarianza de la muestra. Dado que PLS no tiene función de bondad de ajuste global en su función objetivo, aplicar estas métricas equivale a juzgar una herramienta (el martillo) por su capacidad para realizar una tarea para la que no fue diseñada (atornillar).

3.4.2 Estado experimental de las métricas alternativas

Aunque metodólogos como Henseler et al. (2016) han propuesto métricas de ajuste específicas para PLS, como el SRMR (*Standardized Root Mean Square Residual*) o las pruebas de ajuste exacto (d_{ULS} , d_{G}), su uso debe ser extremadamente cauteloso.

- **Limitación actual:** Los umbrales de corte (por ejemplo, $\text{SRMR} < 0.08$) son tentativos y no han sido validados robustamente en todas las condiciones de heterogeneidad de datos. Por ello, Hair et al. (2021) advierten que el rechazo de un modelo PLS basado únicamente en un "mal ajuste" según estas métricas provisionales es una práctica desaconsejada.

3.4.3 Objetivo Epistemológico (Explicación vs. Predicción)

Existe una distinción filosófica crucial: un modelo puede tener un "ajuste" excelente (reproducir bien los datos pasados) y, sin

embargo, tener una capacidad nula para predecir eventos futuros. En el ámbito de la gestión estratégica y el marketing, el interés suele centrarse en la capacidad del modelo para anticipar comportamientos (Hair et al., 2017).

- **El cambio de paradigma:** El rigor en PLS-SEM no se demuestra mediante la replicación de covarianzas (ajuste), sino mediante la **precisión predictiva**.

Conclusión del debate:

La calidad científica en PLS-SEM debe juzgarse desplazando el foco del "Fit" a la "Predicción". El investigador debe priorizar la evaluación de la potencia predictiva fuera de muestra (out-of-sample prediction), utilizando herramientas como PLSpredict, y la robustez de los coeficientes estructurales, en lugar de obsesionarse con índices de ajuste global que poseen poco valor diagnóstico en este contexto (Shmueli et al., 2019).

3.5 Síntesis y estándares de reporte académico

La validación estadística carece de impacto si no se comunica con transparencia y rigor. Un error frecuente en investigadores noveles es presentar capturas de pantalla indiscriminadas del software o saturar el texto con índices irrelevantes, omitiendo métricas esenciales para la replicabilidad científica.

Para subsanar esta brecha, la Tabla 9 se presenta con una doble función:

1. **Resumen Ejecutivo:** Compendia los umbrales de decisión aceptados en la literatura contemporánea para aceptar o rechazar hipótesis.
2. **Plantilla de Reporte:** Estructura la jerarquía de información que debe aparecer obligatoriamente en la sección de "Resultados" de una tesis o artículo científico.

Se recomienda al investigador utilizar esta tabla como una "lista de verificación" (*checklist*) antes de enviar su manuscrito. Si su reporte de resultados cubre explícitamente cada una de las fases aquí descritas (Medición, Estructura y Ajuste), estará cumpliendo con los estándares de publicación exigidos por revistas de cuartil superior (Q1/Q2).

Tabla 9

Resumen del protocolo de validación en PLS-SEM (Modelos Reflexivos)

Fase de Validación	Criterio / Métrica	Umbral de Aceptación (Regla General)	Referencia Clave
1. MODELO DE MEDIDA	Cargas Factoriales (Outer Loadings)	$\lambda \geq 0.708$ (Aceptable >0.40 si su eliminación no mejora la fiabilidad, pero <0.70 requiere justificación)	Hair et al. (2021)

Fase de Validación	Criterio / Métrica	Umbral de Aceptación (Regla General)	Referencia Clave
	Consistencia Interna (Reliability)	Alpha de Cronbach: 0.70 - 0.95 Fiabilidad Compuesta (rho_c): 0.70 - 0.95	Nunnally & Bernstein (1994)
	Validez Convergente	AVE ≥ 0.50 (El constructo explica >50% de la varianza de sus ítems)	Bagozzi & Yi (1988)
	Validez Discriminante	HTMT ratio < 0.85 (Estricto) o < 0.90 (Conceptos similares) IC del HTMT no debe incluir el 1.	Henseler et al. (2015)
2. MODELO ESTRUCTURAL	Colinealidad	VIF < 3.0 (Ideal) o VIF < 5.0 (Tolerable)	Hair et al. (2021)
	Significancia de Rutas (Path Coefficients)	t-value > 1.96 (p < 0.05) IC del Bootstrap (BCa) no debe incluir el 0.	Preacher & Hayes (2008)
	Coficiente de Determinación	R ² \approx 0.75 (Sustancial), 0.50 (Moderado), 0.25 (Débil)	Hair et al. (2021)
	Tamaño del Efecto	f ² \geq 0.02 (Pequeño), f ² \geq 0.15 (Medio), f ² \geq 0.35 (Grande)	Cohen (1988)
	Relevancia Predictiva	Q ² > 0 (Tiene relevancia predictiva) Evaluación preferente mediante PLSpredict.	Shmueli et al. (2019)

Fase de Validación	Criterio / Métrica	Umbral de Aceptación (Regla General)	Referencia Clave
3. AJUSTE GLOBAL	Ajuste del Modelo (<i>Model Fit</i>)	SRMR < 0.08 (<i>Uso diagnóstico; no usar como criterio único de rechazo</i>).	Henseler et al. (2016)

Nota. Los umbrales presentados son referenciales para investigaciones en ciencias sociales y empresariales; pueden variar según la madurez de la teoría.

3.6 Guía de lecturas avanzadas y modelos de referencia

El protocolo de validación expuesto en las secciones precedentes constituye el estándar metodológico actual. Sin embargo, la investigación científica es una disciplina viva que se adapta a las particularidades de cada objeto de estudio. Para facilitar la transición de la teoría a la práctica investigativa, ofrecemos aquí un compendio de lecturas complementarias y modelos de referencia.

Esta sección se distingue de la bibliografía general por su carácter instrumental. Los siguientes trabajos han sido seleccionados por su rigor en la ejecución del análisis post-hoc y la claridad en la presentación de la evidencia empírica. Se recomienda al investigador novelesco utilizar estos textos como "plantillas de calidad" (*benchmark*) para evaluar la estructura y profundidad de sus propios reportes de resultados en tesis o artículos científicos

1. Soriano, J.L. & Mejía-Trejo, J. (2022). Modelado de Ecuaciones Estructurales en el campo de las Ciencias de la Administración. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 33, 242-263.

<https://www.econstor.eu/bitstream/10419/286270/1/1814673792.pdf>

· Analiza la pertinencia y aplicación práctica del SEM en la gestión y administración, y revisa comparativamente los software disponibles en el área empresarial.

2. Ikram, A.A.D.W., et al. (2025). Empleo de modelos de ecuaciones estructurales para analizar factores de políticas públicas en gobiernos locales. *Sustainability*, 17(15), 6855.
<https://www.mdpi.com/2071-1050/17/15/6855>
· Presenta aplicaciones de SEM para medir el impacto de variables latentes en la gestión pública y políticas públicas utilizando LISREL.
3. Maynez Guaderrama, A.I. & López Torres, V.G. (2025). Modelos de ecuaciones estructurales como técnica de análisis en ciencias administrativas. Astra Editorial. <https://astraeditorialshop.com/wp-content/uploads/2025/04/Modelos-de-ecuaciones-estructurales-como-tecnica.pdf>
· Libro colectivo con ejemplos detallados de SEM tanto en gestión pública como en empresas, incluyendo aplicaciones con software gratuito (R, PLS-SEM, multigrupo).
4. Natesan, S.D. (2023). Un enfoque de ecuaciones estructurales para la implementación de políticas públicas. *Journal of Policy Modeling*, 45(2), 401-417.
<https://www.sciencedirect.com/science/article/pii/S097038962300307>
· Utiliza SEM para evaluar cómo variables de redes sociales y demografía influyen en la implementación de políticas públicas.
5. Vidal-Portilla, E., et al. (2023). Modelamiento mediante ecuaciones estructurales (PLS-SEM) en la investigación en ciencias empresariales. *Contabilidad y Negocios*, 18(36).
<https://revistas.pucp.edu.pe/index.php/contabilidadyNegocios/artic le/view/26930>

- Ejemplo de uso de PLS-SEM aplicado a factores de competitividad en empresas públicas y privadas.
6. Ruiz, J. & Guerrero, J. (2025). Tutorial de modelado de ecuaciones estructurales con software libre para gestión pública y empresarial. Astra Editorial. https://astraeditorialshop.com/wp-content/uploads/2025/04/Modelos-de-ecuaciones-estructurales-como-tecnica_.pdf
 - Incluido dentro del libro anterior, muestra paso a paso cómo usar R y paquetes libres para SEM en análisis de gestión pública.
 7. “Ecuaciones Estructurales Aplicadas a la Toma de Decisiones”. Revista Internacional de Ciencias Sociales y Humanidades, 13(1), 2024. <https://www.reincisol.com/ojs/index.php/reincisol/article/view/1007>
 - Analiza la utilidad del modelado SEM en la toma de decisiones estratégicas en el sector público y en empresas.

Referencias

- Bagozzi, R. P., y Yi, Y. (1988). On the evaluation of structural equation models. *Journal of the Academy of Marketing Science*, 16(1), 74–94. <https://doi.org/10.1007/BF02723327>
- Bagozzi, R. P., y Yi, Y. (2012). Specification, evaluation, and interpretation of structural equation models. *Journal of the Academy of Marketing Science*, 40(1), 8–34. <https://doi.org/10.1007/s11747-011-0278-x>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2^a ed.). Lawrence Erlbaum Associates.
- Gregory, R. J. (1980). *Psychological testing: History, principles, and applications*. Allyn & Bacon.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., y Sarstedt, M. (2017). Mirror, mirror on the wall: A comparative evaluation of composite-based structural equation modeling methods. *Journal of the Academy of Marketing Science*, 45(5), 616–632. <https://doi.org/10.1007/s11747-017-0517-x>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., y Sarstedt, M. (2021). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (3^a ed.). Sage Publications.
- Hair, J. F., Risher, J. J., Sarstedt, M., y Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>

- Henseler, J., Hubona, G., y Ray, P. A. (2016). Using PLS path modeling in new technology research: Updated guidelines. *Industrial Management & Data Systems*, 116(1), 2–20. <https://doi.org/10.1108/IMDS-09-2015-0382>
- Henseler, J., Ringle, C. M., y Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Henseler, J., y Sarstedt, M. (2013). Goodness-of-fit indices for partial least squares path modeling. *Computational Statistics*, 28(2), 565–580. <https://doi.org/10.1007/s00180-012-0317-1>
- Nunnally, J. C., y Bernstein, I. H. (1994). *Psychometric theory* (3^a ed.). McGraw-Hill.
- Preacher, K. J., y Hayes, A. F. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in multiple mediator models. *Behavior Research Methods*, 40(3), 879–891. <https://doi.org/10.3758/BRM.40.3.879>
- Rigdon, E. E. (2012). Rethinking partial least squares modeling: In praise of simple methods. *Long Range Planning*, 45(5–6), 341–358. <https://doi.org/10.1016/j.lrp.2012.09.010>
- Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., y 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>

Westland, J. C. (2015). *Structural Equation Models: From Paths to Networks*. Springer. <https://doi.org/10.1007/978-3-319-16507-3>

CAPITULO IV

MODELADO DE MEDIDA REFLEXIVO: FUNDAMENTOS Y CRITERIOS DE DECISIÓN

La Lógica del Espejo

En el ámbito de las ciencias empresariales y del comportamiento, nos enfrentamos constantemente al reto de medir lo intangible. La mayoría de los fenómenos que estudiamos como la satisfacción del cliente, la lealtad a la marca o el liderazgo transformacional son constructos latentes: conceptos teóricos que existen en la realidad pero que no podemos observar ni cuantificar de manera directa.

Para abordar este desafío, la aproximación más utilizada es el Modelo de Medida Reflexivo. Este enfoque asume una postura epistemológica específica: el constructo es una realidad subyacente que existe independientemente de cómo la midamos y que causa la variación en los indicadores observables.

Una analogía útil para comprender esta relación causal es la "Lógica del Espejo" o del termómetro:

Imaginemos un termómetro (indicador) midiendo la temperatura ambiental (constructo latente). Cuando la temperatura sube, el nivel de mercurio en el termómetro sube. Es la temperatura la que causa el cambio en el mercurio, y no al revés; el termómetro simplemente "refleja" una realidad preexistente.

Este capítulo profundiza en los fundamentos para validar estos modelos, integrando un flujo operativo de decisión que guía al investigador a través de cuatro filtros de calidad esenciales:

1. **Confiabilidad del indicador:** (Cargas externas).
2. **Consistencia interna:** (Coeficiente compuesto y Rho_A).
3. **Validez convergente:** (Varianza Extraída Promedio - AVE).
4. **Validez discriminante:** (Criterio HTMT).


4.1 Operacionalización del Modelo y Diccionario de Variables

Para aterrizar los conceptos teóricos de la validación reflexiva, utilizaremos a lo largo de este capítulo un caso de estudio transversal: el Modelo de Reputación Corporativa.

Como se ilustra en la **Figura 6**, este modelo conceptual propone una estructura de relaciones donde la percepción del cliente sobre la empresa (Competencia y Simpatía) influye en su Satisfacción y, en última instancia, en su Lealtad. Sin embargo, antes de poder evaluar estas hipótesis causales (modelo estructural), debemos asegurarnos de medir correctamente cada una de las "piezas" del modelo.

Figura 6

Modelo conceptual de Reputación Corporativa



Dado que constructos como la "Competencia" o la "Simpatía" son intangibles y no observables directamente, recurrimos a una serie de indicadores o ítems (preguntas de encuesta) que actúan como manifestaciones visibles de estas variables latentes.

La **Tabla 10** presenta el Diccionario de Variables, detallando la operacionalización técnica del instrumento. En ella se vincula cada constructo teórico con sus ítems específicos y se asignan las etiquetas de código (ej. *comp_1*, *cusl_3*).

Es fundamental reiterar la naturaleza reflexiva de esta medición: la lógica subyacente asume que el constructo es la causa de las respuestas. Por ejemplo, si un cliente posee una alta *Lealtad* (variable latente), esto provocará que puntúe alto simultáneamente en la recomendación (*cusl_1*), la preferencia (*cusl_2*) y la intención de continuidad (*cusl_3*).

Tabla 10

Diccionario de variables y detalles de medición

Constructo (Variable Latente)	Código del Indicador	Enunciado del Ítem (Medición)
Competencia (COMP)	<i>comp_1</i>	[La empresa] es un competidor líder en su mercado.
	<i>Comp_2</i>	Hasta donde yo sé, [la empresa] es reconocida mundialmente.
	<i>comp_3</i>	Creo que [la empresa] tiene un rendimiento superior.
Simpatía / Atracción (LIKE)	<i>like_1</i>	[La empresa] es una organización con la que puedo identificarme mejor que con otras.

Constructo (Variable Latente)	Código del Indicador	Enunciado del Ítem (Medición)
	like_2	Me arrepentiría más si [la empresa] dejara de existir que si lo hicieran otras.
	like_3	Considero que [la empresa] es una compañía agradable.
Satisfacción (CUSA)	cusa	En términos generales, estoy satisfecho con [la empresa]. (Ítem único)
Lealtad (CUSL)	cusl_1	Recomendaría [la empresa] a amigos y familiares.
	cusl_2	Si tuviera que elegir de nuevo, elegiría a [la empresa] como mi proveedor.
	cusl_3	Seguiré siendo cliente de [la empresa] en el futuro.

4.2 Características Distintivas y Lógica Causal

Para comprender la naturaleza reflexiva sin ambigüedades, debemos analizar sus propiedades fundamentales y realizar un ejercicio conceptual sobre la dirección de la causalidad.

A) El Fenómeno como Causa Raíz

En una especificación reflexiva, la dirección causal fluye estrictamente desde el constructo hacia los indicadores (Constructo → Indicadores). Esto implica que los indicadores son manifestaciones subordinadas al constructo.

Para ilustrarlo, realicemos un experimento mental con el constructo latente "Satisfacción del Cliente". Este constructo representa un estado psicológico interno e invisible. Imaginemos que lo medimos a través de dos indicadores observables:

- **Indicador 1 (Recomendación):** "Hablaré bien de la empresa a mis conocidos".
- **Indicador 2 (Recompra):** "Tengo la intención de volver a comprar en el futuro".

Bajo la lógica reflexiva:

1. **Causalidad:** Es el hecho de *estar satisfecho* lo que provoca que el cliente marque puntuaciones altas en ambos indicadores. La satisfacción es el antecedente necesario.
2. **Covariación simultánea (El efecto "espejo"):** Dado que ambos indicadores son causados por la misma fuente subyacente, actúan como un reflejo simultáneo. Si el nivel de satisfacción aumenta (por ejemplo, tras un servicio excelente), teóricamente esperamos que las puntuaciones de *Recomendación* y *Recompra* aumenten al unísono (Hair et al., 2021).
3. **Intercambiabilidad:** Debido a que ambos indicadores son manifestaciones del mismo sentimiento central, están altamente correlacionados. Si eliminamos el indicador "Recompra", el constructo "Satisfacción" sigue existiendo y siendo medido por "Recomendación" sin perder su significado teórico (Jarvis et al., 2003).

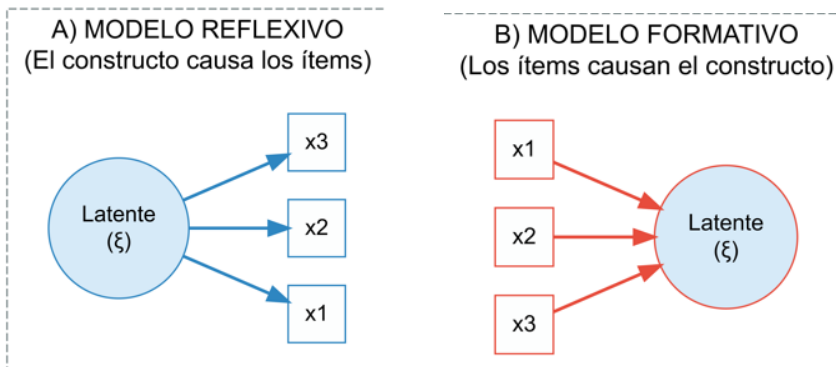
B) Resumen de Propiedades Psicométricas

Siguiendo a Diamantopoulos y Siguaw (2006) y Henseler et al. (2015), un modelo reflexivo cumple las siguientes condiciones:

- **Significado compartido:** Cada indicador capta una parte de la esencia del concepto general.
- **Alta Correlación:** Los valores de los indicadores tienden a moverse juntos.
- **Antecedentes comunes:** Se espera que todos los indicadores tengan patrones de relación similares con otras variables del modelo.

Figura 7

Modelo reflexivo y formativo



Nota: Elaboración basada en Hair et al. (2021).

La Figura 7 presenta la dirección de la causalidad en la medición. En el Panel A (Reflexivo), el constructo latente (círculo) es

la causa raíz; la variación fluye hacia afuera, hacia los indicadores observables (cuadrados). Esto implica que los indicadores están correlacionados. En el Panel B (Formativo), la lógica se invierte: los indicadores son variables exógenas que "inyectan" información para formar el constructo latente; no se asume correlación entre ellos.

4.3 El Algoritmo de Validación: El "Embudo" de Calidad

Una vez definida la naturaleza teórica del modelo, pasamos a la fase de evaluación empírica. Para que un modelo reflexivo sea aceptado científicamente, debe superar cuatro filtros de calidad secuenciales.

Este orden no es arbitrario; es jerárquico. Se le denomina el "Embudo de Calidad" porque no podemos evaluar el constructo (el todo) si los indicadores individuales (las partes) son defectuosos. El investigador debe proceder paso a paso, "depurando" el modelo en cada etapa.

Secuencia de Análisis:

1. **Fiabilidad del Indicador:** *¿Cuánto de la varianza del ítem explica el constructo? (Análisis de Cargas).*
2. **Consistencia Interna:** *¿Están los indicadores fuertemente correlacionados entre sí, demostrando que miden lo mismo? (Alfa de Cronbach y Rho_A).*

3. **Validez Convergente:** *¿El constructo explica, en promedio, más de la mitad de la varianza de sus propios indicadores? (AVE).*
4. **Validez Discriminante:** *¿Es el constructo empíricamente distinto de otros constructos en el modelo? (Criterio HTMT).*

4.4 **Paso 1: Fiabilidad Individual del Indicador (Cargas Externas)**

El primer filtro crítico en nuestro "embudo de calidad" se centra en el nivel más básico: el ítem. Antes de validar el constructo como un todo, debemos asegurarnos de que cada una de sus partes (los indicadores) sea fiable.

La métrica fundamental en esta etapa es la Carga Externa (*Outer Loading*), denotada usualmente como lambda. Estadísticamente, este valor representa la correlación bivariada simple entre el indicador observable y su constructo latente asociado. Cuanto mayor sea la carga, mayor es la cantidad de varianza del indicador que es explicada por el constructo, y menor es la varianza de error.

4.4.1 **La Regla Dorada del 0.708**

Aunque la literatura clásica en psicometría a menudo citaba 0.70 como un punto de corte aceptable, el rigor metodológico actual en PLS-SEM exige una justificación matemática precisa para establecer el umbral de aceptación.

- **El Fundamento Matemático:** La fiabilidad del indicador se calcula elevando la carga al cuadrado (λ^2).
- **El Umbral:** Una carga de 0,708 elevada al cuadrado es exactamente 0.50 ($0,708^2 = 0.50$).
- **La Interpretación:** Este valor es el punto de inflexión donde el constructo explica el 50% de la varianza del indicador. Si la carga es menor a 0,708, la varianza de error supera a la varianza explicada, lo cual debilita la fiabilidad del instrumento.

Por tanto, el Criterio de Aceptación Estándar es buscar cargas $\geq 0,708$ (Hair et al., 2022).

4.4.2 La "Zona Gris": Protocolo de depuración de indicadores

En la investigación aplicada a las ciencias empresariales, es habitual enfrentarse a indicadores con cargas moderadas, situadas en lo que llamamos la "zona gris" (entre 0,40 y 0,708). Esto es frecuente cuando se utilizan escalas nuevas o adaptadas a contextos culturales específicos (Hulland, 1999).

Ante estas cargas, el investigador no debe actuar automáticamente. Eliminar indicadores precipitadamente puede socavar la validez de contenido del estudio (es decir, dejar de medir una faceta importante del fenómeno).

Protocolo de Decisión Jerárquica:

1. Zona de eliminación automática (Cargas < 0,40):

- **Acción:** Eliminar siempre.
- **Razón:** Estos ítems aportan más ruido que señal. Su permanencia distorsiona el modelo estructural y las relaciones causales.

2. Zona de análisis condicional (Cargas entre 0,40 y 0,708):

- **Acción:** Analizar el impacto de la eliminación.
- **Regla de retención:** Si el constructo ya cumple con los criterios de Fiabilidad Compuesta y Validez Convergente ($AVE \geq 0.50$) con el ítem incluido, se debe mantener el indicador.
- **Regla de eliminación:** Solo se elimina el indicador si, y solo si, dicha acción conlleva una mejora sustancial que permita al constructo alcanzar los umbrales mínimos de AVE o Fiabilidad Compuesta.

4.4.3 Aplicación al caso de estudio

Situación: En nuestro modelo de Reputación Corporativa, el indicador *COMP_3* ("La empresa es líder en el mercado") presenta una carga externa de 0.60. Esto lo sitúa en la "Zona Gris".
¿Debemos borrarlo?

Decisión Analítica:

1. No lo borramos inmediatamente.
2. Miramos el AVE del constructo *Competencia*.
3. **Escenario A:** Si el AVE es 0.53 (superior a 0.50), mantenemos *COMP_3*. Aunque su carga es moderada, el ítem aporta información conceptual valiosa sobre el liderazgo de mercado y no daña la validez general.
4. **Escenario B:** Si el AVE es 0.46 (inferior a 0.50), entonces procedemos a eliminar *COMP_3*. Su baja carga está "arrastrando" el promedio hacia abajo, impidiendo la validación del constructo.

4.5 Paso 2: Consistencia interna (fiabilidad del constructo)

Una vez que hemos validado y purgado los indicadores individuales (Paso 1), debemos elevar la mirada hacia el constructo en su conjunto. El objetivo en esta etapa es confirmar la consistencia interna: *¿Miden todos los indicadores conservados el mismo fenómeno subyacente de manera coherente?*

Históricamente, la investigación en ciencias sociales ha dependido casi exclusivamente del Alfa de Cronbach. Sin embargo, en el contexto moderno de PLS-SEM, este indicador presenta una limitación crítica: asume tau-equivalencia. Esto significa que presupone que todos los indicadores contribuyen exactamente con la misma fuerza a la medición del constructo (cargas iguales), una asunción que rara vez se cumple en la realidad empírica (Hair et al., 2022).

Para superar esta limitación y evitar sesgos, recomendamos un análisis triangular que evalúe la fiabilidad desde tres perspectivas complementarias:

4.5.1 La Tríada de Fiabilidad

1. Alfa de Cronbach (alpha): El Límite Inferior

Es la medida clásica basada en las intercorrelaciones de los ítems. En PLS-SEM, tiende a subestimar la verdadera fiabilidad del constructo debido a su sensibilidad al número de ítems. Lo utilizamos como el umbral conservador o "piso" de la fiabilidad (Cronbach, 1951).

2. Fiabilidad Compuesta (ρ_c): El Límite Superior

Propuesta originalmente por Jöreskog (1971), esta métrica pondera los indicadores según sus cargas individuales (dando más peso a los ítems más fuertes). A diferencia del Alfa, tiende a sobreestimar la fiabilidad interna. Lo interpretamos como el "techo" de la fiabilidad.

3. ρ_A (ρ_A): La Medida Exacta

Introducido por Dijkstra y Henseler (2015), el coeficiente ρ_A es actualmente la medida más robusta y consistente para modelos PLS. Se sitúa matemáticamente entre el Alfa y la Fiabilidad Compuesta, ofreciendo la

estimación más precisa de la fiabilidad de la población (Hair et al., 2019).

Síntesis Metodológica:

Un constructo sólido debería mostrar un patrón donde:

Alfa de Cronbach $< \rho_A < \text{Fiabilidad Compuesta}$

4.5.2 Criterios de decisión y la paradoja del "exceso de fiabilidad"

Para aceptar la consistencia interna de un constructo reflexivo, debemos aplicar un criterio de doble límite:

A) El Umbral Mínimo (¿Es fiable?)

Siguiendo a Nunnally y Bernstein (1994), se aceptan valores $\geq 0,70$ para investigaciones confirmatorias. En fases exploratorias muy tempranas, valores entre 0,60 y 0,70 pueden ser tolerados, pero con cautela.

- *Interpretación:* Si el valor es $< 0,60$; el constructo es inestable y los indicadores no están capturando el mismo concepto.

B) El Umbral Máximo (¿Es redundante?)

Aquí reside un error común: creer que "cuanto más alto, mejor".

- **La Regla:** Los valores no deben exceder 0.95.
- **El Problema:** Un coeficiente de 0,98 o 0,99 es problemático. Indica redundancia semántica: los encuestados perciben las preguntas como idénticas, lo que sugiere que no estamos midiendo diferentes matices del constructo, sino repitiendo lo mismo (Drolet y Morrison, 2001). Esto puede inflar artificialmente las correlaciones y generar problemas de colinealidad.

Aplicación al Caso:

Si el constructo Lealtad (CUSA) presenta un $\rho_A = 0.98$, debemos revisar los ítems. Es probable que estemos preguntando "¿Es usted leal?" y "¿Tiene lealtad?" de forma consecutiva. La solución sería eliminar uno de los ítems redundantes para mejorar la parsimonia sin perder fiabilidad.

Tabla 11

Coeficientes de consistencia interna (alpha, rho_A, rho_c)

Rango del Coeficiente	Calificación Técnica	Interpretación Psicométrica	Acción Recomendada para el Investigador
≥ 0.95	Redundancia Severa	Problemático. Indica que los indicadores son virtualmente idénticos, lo	Depurar. Revisar los ítems y eliminar aquellos que sean

Rango del Coeficiente	Calificación Técnica	Interpretación Psicométrica	Acción Recomendada para el Investigador
		que sugiere redundancia semántica en lugar de consistencia real. Puede señalar el fenómeno de straight-lining (respuestas automáticas) por parte de los encuestados (Drolet & Morrison, 2001).	repetitivos. El objetivo es la parsimonia: medir lo mismo con menos preguntas sin perder fiabilidad.
0.90 – 0.95	Excelente	Nivel de fiabilidad ideal para escalas maduras y constructos críticos. Indica una fuerte cohesión entre los ítems sin llegar necesariamente a la redundancia.	Aceptar y Vigilar. Se puede reportar con confianza, pero se recomienda verificar que no exista colinealidad extrema (VIF) entre los indicadores.
0.70 – 0.90	Satisfactorio	El "Estándar de Oro". Cumple con los criterios rigurosos para investigación confirmatoria. Indica que el constructo es estable y replicable (Nunnally & Bernstein, 1994).	Aceptar. Proceder con el análisis de validez convergente. Es el rango seguro para publicar en revistas de alto impacto.
0.60 – 0.70	Aceptable (Condicional)	Límite inferior permitido exclusivamente para investigación exploratoria o escalas en fases tempranas de desarrollo (Hair et al., 2019).	Justificar. Si su estudio es confirmatorio, intente mejorar la escala. Si es exploratorio, reporte esta limitación explícitamente en la discusión.
< 0.60	Insuficiente	Deficiente. Los indicadores no convergen en un solo constructo. Existe una falta	Rechazar o Reespecificar. El constructo no es válido. Se requiere

Rango del Coeficiente	Calificación Técnica	Interpretación Psicométrica	Acción Recomendada para el Investigador
		de homogeneidad interna crítica.	eliminar ítems problemáticos o replantear la teoría subyacente.

Fuente: Elaboración basada en Hair et al. (2022) y Diamantopoulos et al. (2012)

4.6 Paso 3: Validez Convergente (AVE)

Tras verificar que los indicadores son fiables individualmente y consistentes entre sí, el tercer filtro del "embudo de calidad" examina la validez convergente. Este concepto responde a una pregunta estructural crítica: *¿El constructo logra explicar la varianza de sus indicadores mejor que el error de medición?*

La métrica estándar para evaluar esta propiedad es la Varianza Extraída Promedio (AVE, por sus siglas en inglés: *Average Variance Extracted*), propuesta originalmente por Fornell y Larcker (1981).

4.6.1 Definición y lógica matemática

Técnicamente, la AVE se define como la media aritmética de las cargas al cuadrado de todos los indicadores asociados a un constructo.

$$AVE = \frac{\sum \lambda_i^2}{n}$$

Donde λ_i es la carga de cada indicador y n es el número de indicadores.

En términos sencillos, la AVE es una medida de "fuerza bruta" del constructo: cuantifica, en promedio, qué porcentaje de la información contenida en los ítems proviene realmente de la variable latente y no del ruido aleatorio o error.

4.6.2 El Umbral crítico: La Regla del 50%

Para que un constructo reflexivo sea considerado válido, debe cumplir con el siguiente criterio universalmente aceptado (Hair et al., 2022):

- **Criterio: $AVE \geq 0,50$.**
- **Interpretación del Umbral:** Este valor de 0.50 no es arbitrario. Indica que el constructo es capaz de explicar más de la mitad (50 %) de la varianza de sus propios indicadores.
- **La Consecuencia del Fracaso:** Si el AVE es menor a 0.50 (por ejemplo, 0.45), significa que la varianza del error es mayor que la varianza explicada. En tal escenario, nuestros instrumentos están capturando más "ruido" que "señal", invalidando cualquier conclusión teórica posterior sobre ese constructo.

4.6.3 Estrategia de corrección (Troubleshooting)

¿Qué sucede si un constructo importante, como "Competencia" (COMP), arroja un AVE de 0,46? El investigador no debe descartar el constructo inmediatamente.

La solución reside en la naturaleza iterativa del modelo reflexivo:

1. Revisar las cargas externas (Paso 1).
2. Identificar el indicador con la carga más baja (por ejemplo, *COMP_4* con $\lambda = 0,55$).
3. Eliminar este indicador y recalcular el modelo.
4. Al eliminar el ítem más débil, el promedio de los restantes subirá, permitiendo probablemente que el AVE supere el umbral de 0,50.

Aplicación al Caso:

En nuestro estudio de Reputación, el constructo Simpatía (LIKE) obtuvo inicialmente un AVE de 0,58; Dado que $0.58 > 0.50$, concluimos que existe validez convergente: los indicadores LIKE_1, LIKE_2 y LIKE_3 convergen adecuadamente para representar el concepto de simpatía corporativa, validando la "esencia" del constructo.

4.7 Paso 4: Validez Discriminante (La Prueba de Fuego)

Llegamos al último y más riguroso filtro de nuestro "embudo de calidad". Tras confirmar que los constructos son fiables (Pasos 1 y 2) y que explican bien su propia varianza (Paso 3), surge una interrogante crítica: ¿Son los constructos realmente distintos entre sí?

La validez discriminante busca demostrar la unicidad empírica de un constructo. En nuestro caso de estudio, teóricamente sabemos que "Competencia" (habilidad técnica) y "Simpatía" (atractivo emocional) son conceptos diferentes que contribuyen a la Reputación. Sin embargo, estadísticamente, si estos constructos están correlacionados en exceso (por ejemplo, $r > 0,90$), sufrimos de colinealidad teórica. Esto implica que, para los encuestados, ambos conceptos son indistinguibles, y modelarlos por separado sería redundante y engañoso.

4.7.1 La Evolución Metodológica: Del Fornell-Larcker al HTMT

Para evaluar esta propiedad, la historia del SEM ha transitado por dos eras marcadas:

A) El Ocaso del Criterio Fornell-Larcker

Durante décadas, el estándar de oro fue el criterio propuesto por Fornell y Larcker (1981). Este método postula que la raíz cuadrada del AVE de un constructo debe ser mayor que su correlación con cualquier otro constructo del modelo ($\sqrt{AVE} > r$).

- **El Problema:** Estudios de simulación recientes (Henseler et al., 2015) han revelado que este criterio carece de sensibilidad. Frecuentemente indica que hay validez discriminante cuando en realidad no la hay (falsos positivos).
- **Uso Actual:** Hoy en día, se recomienda reportarlo solo como una métrica complementaria o "de primera vista", pero nunca como la única evidencia de validez en revistas de alto impacto (Franke y Sarstedt, 2019).

B) El Nuevo Estándar: HTMT (Heterotrait-Monotrait Ratio)

Para superar las deficiencias del método clásico, Henseler et al. (2015) introdujeron el **Ratio Heterotrait-Monotrait (HTMT)** de correlaciones.

Técnicamente, el HTMT es una estimación de cuál sería la verdadera correlación entre dos constructos si estos fueran medidos sin error (perfectamente fiables). Es, por tanto, una corrección por atenuación.

4.7.2 Criterios de decisión e inferencia estadística

El análisis del HTMT se realiza en dos niveles: la magnitud del valor y la inferencia basada en intervalos de confianza.

1. Evaluación de la Magnitud (Punto de Corte)

Dependiendo de la cercanía teórica de los constructos, utilizamos dos umbrales:

- **Criterio Conservador (HTMT < 0,85):** Se utiliza cuando los constructos son conceptualmente muy distintos (ej. *Satisfacción* vs. *Precio*). Este es el umbral más seguro y recomendado (Kline, 2011).
- **Criterio Liberal (HTMT < 0,90):** Aceptable cuando los constructos son conceptualmente similares (ej. *Satisfacción* vs. *Lealtad*). Si el valor supera 0,90; existe una falta de validez discriminante definitiva (Goldah y Zwicker, 2016).

2. Inferencia Estadística (Bootstrapping): La Prueba Definitiva

Más allá del valor puntual (ej. 0,88), el rigor científico exige analizar el Intervalo de Confianza generado mediante bootstrapping (generalmente al 95 % y con 5,000 submuestras).

- **La Regla de Oro:** El intervalo de confianza del HTMT no debe incluir el valor 1,0.

- **Interpretación:** Si el intervalo es, por ejemplo, $[0,82; 1,05]$, significa que existe una probabilidad estadística de que la correlación real sea 1,0 (identidad perfecta). En este escenario, no hay validez discriminante, independientemente de que el valor medio sea bajo.

Aplicación al Caso:

Al analizar la relación entre Competencia y Simpatía en nuestro modelo, obtenemos un HTMT de 0.82.

- *Evaluación Puntual:* Cumple el criterio conservador ($< 0,85$).
- *Evaluación Inferencial:* Al ejecutar el bootstrapping, el intervalo de confianza (Bias-Corrected) resultante es $[0,76; 0,89]$.
- *Conclusión:* Dado que el intervalo no incluye el 1,0; podemos afirmar con un 95 % de confianza que la Competencia y la Simpatía son fenómenos empíricamente distintos en la mente de nuestros consumidores.

Tabla 12*Resumen de Criterios de Validación para Modelos Reflexivos*

Etapa de Validación	Métricas y Umbrales Críticos	Interpretación y Aplicación al Caso
1. Fiabilidad del Indicador	<p>Carga Externa (lambda) ≥ 0.708</p> <p>Zona de Decisión (0.40 - 0.708):</p> <p>Solo eliminar si mejora el AVE o la fiabilidad compuesta.</p>	<p>El constructo explica más del 50 % de la varianza del indicador ($0.708^2 = 0.50$).</p> <p>Caso: Si un ítem de "Competencia" carga bajo (ej. 0.50), verificar si borrarlo aumenta el AVE del constructo antes de decidir.</p>
2. Consistencia Interna	<p>Rango Ideal: $0.70 \leq \text{Valor} \leq 0.95$</p> <p>Métricas:</p> <p>1. rho_A (Rho_A): Medida prioritaria (más exacta).</p> <p>2. rho_c (Fiabilidad Compuesta): Límite superior.</p> <p>3. alpha de Cronbach: Límite inferior.</p>	<p>Evalúa si los indicadores miden coherentemente el mismo concepto.</p> <ul style="list-style-type: none"> • < 0.70: Falta de estabilidad. • > 0.95: Redundancia. Los ítems son repetitivos (colinealidad) y no aportan matices nuevos. <p>Caso: Buscamos que Lealtad (CUSA) tenga un rho_A equilibrado, evitando valores de 0.98 o 0.99.</p>
3. Validez Convergente	<p>AVE (Varianza Extraída Promedio) $\geq 0,50$</p>	<p>El constructo captura la esencia de sus indicadores mejor que el error de medición.</p> <p>Caso: Confirma que el conjunto de ítems de Simpatía (LIKE) converge en una sola idea sólida, explicando más de la mitad de su información.</p>

Etapa de Validación	Métricas y Umbrales Críticos	Interpretación y Aplicación al Caso
<p>4. Validez Discriminante</p>	<p>Criterio Principal: HTMT</p> <ul style="list-style-type: none"> • Conservador: < 0,85 • Liberal: < 0,90 <p>• IC (Bootstrap): No debe incluir el 1,0</p> <p>Criterio Complementario:</p> <p>Fornell-Larcker ($\sqrt{AVE} > r$)</p>	<p>Garantiza la unicidad empírica del constructo.</p> <p>Caso: Demuestra que Competencia es distinto de Simpatía. Si el intervalo de confianza del HTMT entre ellos incluye el 1, estadísticamente son lo mismo (falta de discriminancia).</p>

Adaptado de Hair et al. (2021)

4.8 Reporte de resultados: estándares de publicación

La validación estadística carece de valor si no se comunica con rigor y claridad. El paso final del modelado de medida no es el cálculo, sino la argumentación. Para reportar un modelo reflexivo en una tesis doctoral o un artículo de alto impacto (Q1/Q2), el investigador debe sintetizar la evidencia en dos formatos complementarios: la Tabla Maestra de Validez y la Narrativa Técnica.

A continuación, presentamos una guía basada en los estándares de reporte de Hair et al. (2019).

4.8.1 La Estructura de la tabla maestra

No abrume al lector con múltiples tablas dispersas. Se recomienda consolidar la información de los Pasos 1, 2 y 3 en una sola matriz que permita evaluar la calidad del modelo de un vistazo.

Columnas sugeridas para la tabla:

1. **Constructo:** Nombre de la variable latente (ej. Competencia).
2. **Indicador:** Etiqueta del ítem (ej. COMP_1).
3. **Carga Externa (λ):** Debe ser $> 0,708$.
4. **Alfa de Cronbach (α):** Referencia clásica.
5. **Rho_A:** Medida de consistencia preferida.
6. **Fiabilidad Compuesta (ρ_c):** Límite superior.
7. **AVE:** Varianza Extraída Promedio ($> 0,50$).

Nota: La Validez Discriminante (HTMT) suele reportarse en una matriz separada debido a su formato triangular.

4.8.2 Plantilla de Redacción Narrativa ("Fill-in-the-blanks")

A continuación, se presenta un modelo textual estandarizado para reportar los resultados del modelo de medida reflexivo. El investigador puede copiar, pegar y adaptar los espacios marcados entre corchetes [...] con los datos estadísticos obtenidos de su software (SmartPLS, R/seminr, ADANCO, etc.).

Resultados de la Evaluación del Modelo de Medida

"Para determinar la calidad psicométrica del instrumento, se evaluó el modelo de medida reflexivo siguiendo los lineamientos de Hair et al. (2022). El análisis se centró en cuatro criterios secuenciales: fiabilidad del indicador, consistencia interna, validez convergente y validez discriminante.

En primer lugar, se examinó la **fiabilidad individual de los indicadores**. La mayoría de las cargas externas (*outer loadings*) superaron el umbral crítico de **0,708**, indicando que el constructo explica más del 50 % de la varianza del indicador. [**Opcional si hubo eliminación**: Se eliminaron los ítems [**CÓDIGOS, EJ: COMP_3**] debido a cargas bajas (< 0.40) o para mejorar la varianza extraída promedio]. Tras la depuración, las cargas de los indicadores retenidos oscilaron entre [**VALOR MÍNIMO**] y [**VALOR MÁXIMO**], confirmando su robustez individual.

En segundo lugar, se evaluó la **consistencia interna** utilizando el coeficiente **Rho_A** (ρ_A), considerado la métrica más precisa para PLS-SEM. Los resultados mostraron valores comprendidos entre [**VALOR MÍNIMO**] y [**VALOR MÁXIMO**] para todos los constructos, situándose dentro del rango ideal (0,70 – 0,95). Asimismo, la Fiabilidad Compuesta (ρ_c) y el Alfa de Cronbach confirmaron esta consistencia, superando en todos los casos el límite de 0,70 y sin presentar evidencia de redundancia (valores $< 0,5$).

En tercer lugar, la **validez convergente** fue demostrada mediante la Varianza Extraída Promedio (AVE). Todos los constructos latentes arrojaron valores de AVE superiores a **0,50**, con un rango de **[VALOR MÍNIMO]** a **[VALOR MÁXIMO]**. Esto ratifica que, en promedio, los constructos explican más de la mitad de la varianza de sus propios indicadores, validando la naturaleza reflexiva de la medición.

Finalmente, se analizó la validez discriminante aplicando el criterio Heterotrait-Monotrait Ratio (HTMT), reconocido por su superioridad frente a métodos clásicos como Fornell-Larcker. Todos los ratios HTMT entre pares de constructos se mantuvieron por debajo del umbral **[CONSERVADOR = 0,85 / LIBERAL = 0,90]**. Adicionalmente, se verificó la inferencia estadística mediante el procedimiento de *bootstrapping* con 5,000 submuestras; los intervalos de confianza del 95 % (Bias-Corrected) para los valores HTMT **no incluyeron el valor 1,0** en ningún caso.

En conclusión, el modelo de medida reflexivo propuesto demuestra propiedades métricas satisfactorias, permitiendo proceder con la evaluación del modelo estructural."

Notas para el uso de la plantilla:

1. **[VALOR MÍNIMO/MÁXIMO]:** No es necesario listar cada valor en el texto si ya están en la tabla. Mencionar el rango (ej. "entre 0,78 y 0,92") facilita la lectura.

2. **[OPCIONAL]:** Si no eliminaste ningún indicador, simplemente borra esa frase.
3. **[UMBRAL HTMT]:** Elige **0,85** si tus constructos son muy distintos (ej. *Precio vs. Calidad*). Elige **0,90** si son conceptualmente cercanos (ej. *Satisfacción vs. Lealtad*).

El texto no debe limitarse a repetir los números de la tabla, sino a interpretar el cumplimiento de los criterios del "Embudo de Calidad".

A continuación, presentamos la redacción plantilla aplicada a nuestro Caso de Estudio de Reputación Corporativa, lista para ser adaptada:

Resultados de la Evaluación del Modelo de Medida:

"La evaluación del modelo de medida reflexivo confirmó la robustez psicométrica de los constructos *Competencia (COMP)*, *Simpatía (LIKE)* y *Lealtad (CUSA)*.

En primer lugar, se verificó la **fiabilidad individual de los indicadores**. Todos los ítems retenidos presentaron cargas externas superiores al umbral crítico de 0,708, lo que garantiza que más del 50 % de la varianza del indicador es explicada por su constructo.

En segundo lugar, la **consistencia interna** fue ratificada mediante un análisis triangular. El coeficiente ρ_A la métrica más consistente para PLS-SEM osciló entre 0,82 y 0,91 para todos los constructos. Estos valores se sitúan en el rango ideal (0,70 – 0,95), confirmando una alta fiabilidad sin caer en problemas de redundancia de ítems.

En tercer lugar, respecto a la **validez convergente**, todos los constructos superaron holgadamente el criterio de Varianza Extraída Promedio (AVE) $\geq 0,50$; Específicamente, el constructo *Competencia* obtuvo un AVE de 0,62; demostrando que captura la esencia del fenómeno mejor que el error de medición.

Finalmente, la **validez discriminante** fue establecida satisfactoriamente según el criterio HTMT (Heterotrait-Monotrait Ratio). Todas las relaciones entre pares de constructos se mantuvieron por debajo del umbral conservador de 0.85. Asimismo, el análisis de intervalos de confianza mediante bootstrapping (5,000 submuestras) indicó que ningún intervalo incluía el valor 1.0, confirmando la independencia empírica de las variables en el modelo."

4.9 Referencias científicas sobre modelos reflexivos.

1. Diamantopoulos, A., & Sigauw, J.A. (2006). Formative versus Reflective Indicators in Organizational Measure Development: A Comparison and Empirical Illustration. *British Journal of Management*, 17(4), 263-282.
https://www.researchgate.net/publication/227631735_Formative_v_ersus_Reflective_Indicators_in_Organizational_Measure_Development_A_Comparison_and_Empirical_Illustration
· Comparación teórica y aplicada de modelos reflexivos y formativos en la medición de constructos empresariales, incluyendo recomendaciones para el uso correcto de indicadores reflexivos en SEM.
2. 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://www.researchgate.net/publication/240275612_A_Critical_Review_of_Construct_Indicators_and_Measurement_Model_Misspecification_in_Marketing_and_Consumer_Research

· Estudia en profundidad la naturaleza reflexiva de los indicadores y el impacto de la misspecificación de modelos en SEM aplicado al marketing.

3. Hair, J.F., Hult, G.T.M., Ringle, C.M., & Sarstedt, M. (2022). A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM). Sage Publications. <https://www.econbiz.de/Record/a-primer-on-partial-least-squares-structural-equation-modeling-pls-sem-hair-joseph/10011566584>
 - Manual fundamental para especificar y validar modelos reflexivos en PLS-SEM, con aplicaciones empresariales prácticas.
4. Levy, J. & Varela, J. (2006). Modelos de medición reflectiva y formativa en la investigación empresarial. Papeles del Psicólogo, 27(3), 167-175. <https://www.papelesdel psicologo.es/pdf/1794.pdf>
 - Presenta teoría y práctica comparada de modelos reflexivos y formativos, con casos empresariales y guía para el análisis SEM en español.
5. Bollen, K.A. (1989). Structural Equations with Latent Variables. Wiley. <https://content.e-bookshelf.de/media/reading/L-806416-d104b86f34.pdf>
 - Explica a fondo el fundamento teórico y la estimación de modelos reflexivos en SEM, aplicados a variables latentes en estudios empresariales.
6. Jöreskog, K.G., & Sörbom, D. (1993). LISREL 8: Structural Equation Modeling with the SIMPLIS Command Language. Scientific Software International. https://www.researchgate.net/publication/232486425_LISREL_8_Structural_Equation_Modeling_with_the_SIMPLIS_Command_Language

- Manual clásico para estimación de modelos reflexivos en SEM y su uso en LISREL.
7. Sarstedt, M., & Mooi, E. (2019). A Concise Guide to Market Research: The Process, Data, and Methods Using SEM. Springer. <https://educons.edu.rs/wp-content/uploads/2020/05/2019A-Concise-Guide-To-Market-Research.pdf>
 - Detalla el proceso de validación, confiabilidad y análisis factorial de modelos reflexivos en investigación empresarial.
 8. Schumacker, R.E. & Lomax, R.G. (2016). Structural Equation Modeling: A Second Course. (PDF - Academia.edu) https://www.academia.edu/13420074/Structural_equation_modeling_A_second_generation_multivariate_analysis
 - Aporta ejemplos de validación y estimación de constructos reflexivos, con análisis SEM enfocado en ciencias empresariales.
 9. 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://www.researchgate.net/publication/235361033_Evaluating_Structural_Equation_Models_with_Unobservable_Variables_and_Measurement_Error
 - Referencia fundamental para evaluar la validez y fiabilidad de modelos reflexivos en estudios empresariales y marketing.
 10. Anderson, J.C., & Gerbing, D.W. (1988). Structural equation modeling in practice: A review and recommended two-step approach. Psychological Bulletin, 103(3), 411-423. https://www.researchgate.net/publication/232497232_Structural_Equation_Modeling_in_Practice_A_Review_and_Recommended_Two-Step_Approach
 - Desarrolla la validación de constructos reflexivos en SEM mediante el enfoque de dos etapas, aplicable a administración y negocios.

Habiendo asegurado que nuestros instrumentos de medición son fiables y válidos (nuestros "ladrillos" son sólidos), el lector podría asumir que el trabajo de medición ha terminado. Sin embargo, ¿qué sucede cuando los indicadores no *reflejan* el constructo, sino que lo *forman*, como en el caso de un "Índice de Riesgo Financiero"?

En el próximo capítulo, abordaremos la otra cara de la moneda: El Modelo de Medida Formativo, donde la lógica del espejo se rompe y las reglas de validación cambian radicalmente.

Referencias:

- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334. <https://doi.org/10.1007/BF02310555>
- Diamantopoulos, A., Sarstedt, M., Fuchs, C., Wilczynski, P., y Kaiser, S. (2012). Guidelines for choosing between multi-item and single-item measures for construct measurement: A predictive validity perspective. *Journal of the Academy of Marketing Science*, 40(3), 434–449. <https://doi.org/10.1007/s11747-011-0300-3>
- Diamantopoulos, A., y Siguaw, J. A. (2006). Formative versus reflective indicators in organizational measure development: A comparison and empirical illustration. *British Journal of Management*, 17(4), 263–282. <https://doi.org/10.1111/j.1467-8551.2006.00500.x>
- Dijkstra, T. K., y 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>
- Drolet, A. L., y Morrison, D. G. (2001). Do we really need multiple-item measures in service research? *Journal of Service Research*, 3(3), 196–204. <https://doi.org/10.1177/109467050133001>
- Fornell, C., y 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>
- Franke, G., y Sarstedt, M. (2019). Heuristics versus statistics in discriminant validity testing: A comparison of four procedures. *Internet Research*, 29(3), 430–447. <https://doi.org/10.1108/IntR-12-2017-0515>

- Hair, J. F., Hult, G. T. M., Ringle, C. M., y Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (3ª ed.). Sage.
- Hair, J. F., Ringle, C. M., y Sarstedt, M. (2021). Partial least squares structural equation modeling. En C. Homburg, M. Klarmann, y A. Vomberg (Eds.), *Handbook of Market Research* (pp. 139–180). Springer. https://doi.org/10.1007/978-3-319-56941-3_8
- Hair, J. F., Risher, J. J., Sarstedt, M., y Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Henseler, J., Ringle, C. M., y Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Hulland, J. (1999). Use of partial least squares (PLS) in strategic management research: A review of four recent studies. *Strategic Management Journal*, 20(2), 195–204. [https://doi.org/10.1002/\(SICI\)1097-0266\(199902\)20:2%253C195::AID-SMJ13%253E3.0.CO;2-7](https://doi.org/10.1002/(SICI)1097-0266(199902)20:2%253C195::AID-SMJ13%253E3.0.CO;2-7)
- Jarvis, C. B., MacKenzie, S. B., y 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://doi.org/10.1086/376806>
- Jöreskog, K. G. (1971). Simultaneous factor analysis in several populations. *Psychometrika*, 36(4), 409–426. <https://doi.org/10.1007/BF02291366>
- Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4ª ed.). Guilford Press.

Nunnally, J. C., y Bernstein, I. H. (1994). *Psychometric theory* (3ª ed.). McGraw-Hill.

Sarstedt, M., Ringle, C. M., y Hair, J. F. (2021). Partial least squares structural equation modeling. En C. Homburg, M. Klarmann, y A. Vomberg (Eds.), *Handbook of Market Research* (pp. 587–632). Springer.

CAPITULO V

MODELOS FORMATIVOS EN SEM

Este capítulo examina los modelos formativos en el Modelado de Ecuaciones Estructurales (SEM), destacando su relevancia estratégica para el análisis de constructos complejos, multidimensionales y multifacéticos en las ciencias empresariales. A diferencia de los modelos reflexivos, en los cuales el constructo latente determina causalmente a sus indicadores, los modelos formativos parten del supuesto de que los indicadores conforman, definen y construyen el constructo, estableciendo una lógica causal ascendente coherente con fenómenos organizacionales de naturaleza estratégica.

Esta especificación conceptual implica la adopción de procedimientos de evaluación diferenciados, orientados a garantizar la validez estadística y la coherencia teórica del modelo. En particular, se abordan de manera sistemática el diagnóstico de colinealidad entre indicadores formativos, el análisis de la significancia y relevancia de los pesos externos, así como la evaluación de la validez convergente mediante modelos de redundancia, en consonancia con los estándares metodológicos contemporáneos del SEM.

Asimismo, el capítulo desarrolla protocolos operativos para el tratamiento de indicadores problemáticos y la depuración de bloques formativos, integrando criterios cuantitativos con juicios conceptuales fundamentados en el dominio sustantivo del estudio. Finalmente, se articula la pertinencia del enfoque formativo en contextos de alto valor gerencial, tales como marketing estratégico, gestión del talento humano, innovación organizacional y transformación digital, posicionando a los modelos formativos como una herramienta analítica clave para la toma de decisiones basada en datos.

5.1 Naturaleza y lógica causal de los modelos formativos

En los modelos formativos, la lógica causal fluye desde los indicadores hacia el constructo latente. Cada indicador representa una dimensión específica, no intercambiable y conceptualmente necesaria del fenómeno que se desea modelar. En este enfoque, el constructo no existe de manera independiente a sus indicadores, sino que es definido y construido por ellos, lo que resulta especialmente pertinente para el análisis de variables estratégicas complejas en las ciencias empresariales.

Bollen y Lennox (1991) establecieron de manera fundacional esta distinción al señalar que, a diferencia de los modelos reflexivos, la omisión de un indicador formativo relevante no solo reduce la precisión de la medición, sino que altera sustantivamente el significado teórico del constructo. En consecuencia, los modelos formativos se conciben como

índices compuestos, cuyo objetivo es capturar exhaustivamente el dominio conceptual del fenómeno de interés (Diamantopoulos, 1999; Wold, 1982).

Desde una perspectiva aplicada, esta lógica es coherente con constructos como *calidad del servicio*, *capacidad innovadora*, *madurez digital* o *valor percibido*, en los cuales dimensiones como precio, accesibilidad, confiabilidad o soporte tecnológico no son manifestaciones del constructo, sino sus componentes constitutivos.

La implicación metodológica central es que la validez de un constructo formativo depende primariamente de la validez de contenido, y no de la consistencia interna. Por ello, la especificación del modelo es eminentemente teórica y debe estar respaldada por una justificación conceptual rigurosa para cada indicador incluido (Petter, Straub, y Rai, 2007). En términos gerenciales, esta decisión define qué palancas estratégicas integran el concepto que será utilizado para la toma de decisiones.

5.1.1 Diagnóstico estadístico: colinealidad y redundancia

Los modelos formativos presentan desafíos estadísticos específicos, siendo los más relevantes la colinealidad y la redundancia entre indicadores. La colinealidad ocurre cuando dos o más indicadores formativos están altamente correlacionados, lo que puede inflar las varianzas de los pesos estimados y comprometer la estabilidad del modelo.

MacKenzie, Podsakoff y Jarvis (2005) advierten que, a diferencia de los modelos reflexivos donde una alta correlación es deseable, en los modelos formativos una colinealidad excesiva puede distorsionar la interpretación de la contribución causal de cada indicador. La redundancia, por su parte, se manifiesta cuando varios indicadores capturan esencialmente la misma dimensión conceptual, sin aportar información incremental.

No obstante, Diamantopoulos, Riefler y Roth (2008) sostienen que cierto grado de colinealidad es frecuente e incluso esperado en modelos formativos, recomendando el uso del Factor de Inflación de la Varianza (**VIF**) como criterio operativo para su diagnóstico. En el contexto del PLS-SEM, valores de VIF inferiores a 3.3 o 5.0 son generalmente aceptados como indicativos de colinealidad tolerable (Hair et al., 2022).

Desde una perspectiva empresarial, cuando se detecta colinealidad problemática, puede considerarse la depuración del bloque formativo mediante la eliminación de indicadores redundantes, siempre que dicha decisión no comprometa la validez conceptual del constructo. Hair et al. (2017) enfatizan que esta evaluación debe equilibrar criterios estadísticos con la importancia estratégica relativa de cada indicador.

5.1.2 Interpretación de parámetros: peso versus carga

La correcta interpretación de los parámetros es un aspecto crítico en los modelos formativos. En este tipo de especificación, el peso externo (weight) representa el coeficiente de regresión estandarizado que refleja la

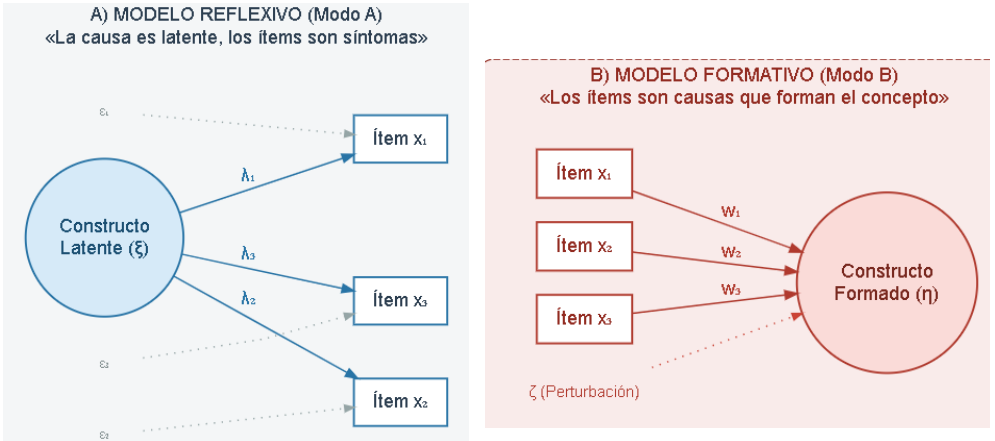
contribución causal y relativa de cada indicador en la formación del constructo. Por ello, el peso constituye el parámetro principal de interés analítico (Jarvis, MacKenzie, y Podsakoff, 2003).

En contraste, la carga externa (loading) expresa la correlación simple entre el indicador y el constructo. Si bien este parámetro es central en los modelos reflexivos, en los modelos formativos cumple un rol secundario y diagnóstico. Henseler, Ringle y Sarstedt (2015) señalan que cargas extremadamente bajas pueden alertar sobre problemas de validez de contenido o una especificación conceptual deficiente, aun cuando el peso resulte significativo.

Desde una lógica gerencial, esta distinción es fundamental. Mientras el peso permite identificar qué dimensión ejerce mayor impacto directo en la construcción del constructo (por ejemplo, qué componente del valor percibido es más determinante), la carga ofrece una señal complementaria sobre la coherencia empírica del indicador. En consecuencia, la priorización estratégica de recursos debe basarse principalmente en la magnitud y significancia de los pesos externos (Chin, 1998).

Figura 8

Modelo de medida reflexivo y formativo



Fuente: Elaboración basada en Hair et al. (2022).

Conexión práctica

🔗 ¿Cómo se ve un Modelo Formativo en la Realidad?

La distinción entre constructos reflectivos y formativos no es solo una cuestión semántica; cambia radicalmente la estrategia de la empresa.

Un ejemplo magistral de esto se encuentra en el Caso de Estudio 9 (Capítulo IX) sobre *Arquitectura Empresarial*. Allí, Ross et al. (2006) modelan la "Arquitectura Tecnológica" no como un reflejo de una sola cosa, sino como la suma de componentes dispares (Nube + Seguridad + Datos). Si desea ver cómo se validan estos constructos formativos y cómo interactúan con la estrategia de negocio, consulte el análisis detallado en la Sección 9.9.

5.2 Criterios para la especificación de constructos formativos

La especificación de un constructo como formativo constituye una de las decisiones metodológicas más críticas en el Modelado de Ecuaciones Estructurales (SEM), especialmente en investigaciones de ciencias empresariales donde se analizan fenómenos estratégicos complejos, multidimensionales y no directamente observables. Esta decisión no puede sustentarse en criterios estadísticos *ex post*, sino que debe responder a una lógica conceptual y causal definida *ex ante*.

En los modelos formativos, los indicadores no reflejan al constructo, sino que lo conforman. Cada indicador representa una dimensión específica y no intercambiable del concepto teórico, de modo que la omisión, adición o sustitución de un indicador modifica sustantivamente el significado del constructo (Bollen y Lennox, 1991; Jarvis et al., 2003). Por ello, la validez del constructo formativo depende primordialmente de la validez de contenido y de la coherencia teórica de su especificación.

Desde una perspectiva aplicada, este enfoque resulta especialmente pertinente para modelar constructos como capacidades organizacionales, madurez digital, calidad percibida, capital intelectual o valor estratégico, donde cada dimensión actúa como una palanca gerencial diferenciada.

5.2.1 Fundamentos conceptuales para la especificación formativa

Un constructo debe ser modelado como formativo cuando cumple simultáneamente con los siguientes criterios:

1. **Direccionalidad causal clara:** la causalidad fluye desde los indicadores hacia el constructo.
2. **No intercambiabilidad de indicadores:** cada indicador captura una faceta única y necesaria.
3. **Ausencia de covariación obligatoria:** los indicadores no necesitan estar altamente correlacionados entre sí.
4. **Exhaustividad conceptual:** el conjunto de indicadores cubre completamente el dominio teórico del constructo.

Estos criterios diferencian de manera inequívoca a los modelos formativos de los reflexivos y justifican la adopción de procedimientos de evaluación específicos (Diamantopoulos y Winklhofer, 2001; Hair et al., 2022).

5.2.2 Generación de indicadores y justificación teórica

La construcción de un bloque formativo es, esencialmente, un ejercicio de **diseño conceptual riguroso**. A diferencia de los modelos reflexivos, donde la depuración estadística puede mejorar la medición, en los modelos formativos **una mala especificación**

teórica no puede ser corregida posteriormente por técnicas estadísticas (Petter et al., 2007).

El proceso recomendado comprende cuatro etapas secuenciales:

1. Delimitación conceptual del constructo

Definir con precisión el constructo, apoyándose en literatura académica consolidada.

2. Identificación del dominio del constructo

Descomponer el concepto en dimensiones o facetas teóricas que, de manera conjunta, lo definan.

3. Operacionalización de indicadores observables

Cada indicador debe representar directamente una dimensión específica, utilizando escalas acordes con su naturaleza (razón, intervalo o conteo).

4. Justificación teórica individual

Cada indicador debe estar explícitamente respaldado por literatura académica que sustente su inclusión como componente causal del constructo.

Conceptos clave en la especificación de constructos formativos

Descripción: Esta tabla sintetiza los elementos conceptuales mínimos que diferencian a los constructos formativos y orientan su correcta especificación metodológica.

Tabla 13*Constructo formativo*

Concepto	Definición operativa	Implicación metodológica
Constructo formativo	Variable latente definida por la combinación causal de sus indicadores.	La omisión de un indicador altera el significado del constructo.
Indicador formativo	Variable observable que define una dimensión específica del constructo.	Cada indicador debe estar teóricamente justificado.

5.2.3 Validación de contenido mediante juicio experto

Dado que la calidad de un constructo formativo depende de su cobertura conceptual, la **validación de contenido con expertos** no es opcional, sino un requisito metodológico indispensable.

El procedimiento recomendado incluye:

- Selección de **5 a 10 expertos** con experiencia académica o profesional en el dominio del constructo.
- Evaluación de cada indicador en términos de **relevancia, claridad y necesidad**.
- Cálculo de índices de consenso, como el **Índice de Validez de Contenido (CVI)** y el **acuerdo interjueces**.

Un nivel de consenso aceptable se alcanza cuando al menos el **80 % de los expertos** considera al indicador como esencial,

garantizando así la exhaustividad y coherencia del bloque formativo (Polit y Beck, 2006).

5.2.4 Evaluación estadística inicial del bloque formativo

Una vez recolectados los datos, se aplican métricas estadísticas específicas cuyo objetivo no es validar la existencia del constructo, sino **diagnosticar problemas de especificación o redundancia**.

Métricas clave para la evaluación inicial de constructos formativos

Descripción: Esta tabla resume las métricas estadísticas indispensables para evaluar la calidad operativa de un bloque formativo antes de su interpretación sustantiva.

Tabla 14

Métricas estadísticas

Métrica	Propósito	Criterio de referencia
VIF	Diagnóstico de colinealidad	Ideal < 3; aceptable < 5
Análisis de redundancia	Validez convergente	$\beta \geq 0.70$ y $R^2 \geq 0.50$
Pesos externos	Contribución causal	Significativos y con signo esperado

La colinealidad elevada no invalida automáticamente un constructo formativo, pero exige decisiones informadas orientadas a preservar la interpretabilidad gerencial del modelo (Hair et al., 2017).

5.2.5 Decisiones sobre retención, combinación o eliminación de indicadores

Las decisiones sobre indicadores formativos deben equilibrar **evidencia empírica y coherencia conceptual**. La eliminación automática basada únicamente en criterios estadísticos puede empobrecer el significado del constructo.

Guía decisional para el tratamiento de indicadores formativos

Tabla 15

Decisiones de Combinación

Evidencia empírica	Diagnóstico	Decisión recomendada
Peso no significativo + VIF alto	Redundancia severa	Eliminación
Peso no significativo + VIF bajo	Baja relevancia conceptual	Eliminación
Peso significativo + VIF alto	Colinealidad tolerable	Retención o combinación teórica

Descripción: Esta tabla proporciona un marco práctico para tomar decisiones informadas sobre indicadores problemáticos en bloques formativos.

5.2.6 Ejemplo aplicado: capacidad de absorción organizacional

La **capacidad de absorción** constituye un ejemplo paradigmático de constructo formativo en ciencias empresariales, dado que solo existe cuando concurren simultáneamente múltiples dimensiones estratégicas.

Tabla 16

Especificación formativa de la capacidad de absorción

Indicador	Dimensión	Sustento teórico
Inversión en I+D	Adquisición	Cohen & Levinthal (1990)
Capacitación tecnológica	Asimilación	Zahra & George (2002)
Adaptación de productos	Transformación	Lane et al. (2006)
Nuevos ingresos	Explotación	Jansen et al. (2005)

Descripción: Esta tabla ilustra cómo cada indicador contribuye causalmente a una dimensión específica del constructo.

Implicación gerencial: la ausencia de cualquiera de estas dimensiones implica que la capacidad de absorción es estructuralmente incompleta, afectando directamente la competitividad de la organización.

La especificación de constructos formativos exige una lógica de diseño conceptual rigurosa, una validación de contenido explícita y una evaluación estadística orientada al diagnóstico, no a la depuración mecánica. Este enfoque permite traducir modelos SEM en herramientas

estratégicas accionables, alineando la modelación estadística con la toma de decisiones empresariales

5.3 El Algoritmo de Evaluación de Modelos Formativos

Una vez especificado el modelo y recolectados los datos, el investigador se enfrenta a la pregunta crítica: *¿Es válido mi constructo?*. A diferencia de los modelos reflexivos, donde buscamos que los ítems se parezcan entre sí (consistencia), en los modelos formativos buscamos que cada ítem aporte información única y relevante (contribución).

Para evaluar esta calidad, **Hair et al. (2022)** proponen un "mapa de ruta" secuencial de tres pasos. Este algoritmo debe ejecutarse en orden estricto, ya que el fallo en una etapa temprana invalida los resultados de las etapas posteriores.

5.3.1 Paso 1: Validación Convergente (El filtro de coherencia)

Antes de analizar los indicadores individuales, debemos asegurar que el constructo, como un todo, tiene sentido. Como se detalló en la sección anterior, esto se realiza mediante el **Análisis de Redundancia**.

- **La Métrica:** Correlación entre el constructo formativo y una medida global (ítem único reflexivo).
- **El Umbral:** ≥ 0.708 .
- **La Decisión:** Si la correlación es inferior a este valor, el constructo formativo no captura adecuadamente el fenómeno

estudiado ($R^2 < 0.50$). En este punto, se debe detener el análisis y revisar la teoría o la calidad de los datos (Cheah et al., 2018).

5.3.2 Paso 2: Diagnóstico de Colinealidad (El filtro de independencia)

En los modelos formativos, la alta correlación entre indicadores es perjudicial (a diferencia de los reflexivos donde es deseable). Si dos indicadores, como *perf_1* y *perf_2*, dicen exactamente lo mismo, sus pesos se desestabilizan y pierden significancia estadística.

- **La Métrica:** Factor de Inflación de Varianza (VIF).
- **El Umbral:**
 - **VIF ≥ 5 :** Crítico. Indica redundancia severa. Acción: Eliminar el indicador o consolidarlo con otro.
 - **VIF < 3 :** Ideal. Indica que el indicador aporta información única.
- **La Decisión:** Asegúrese de que todos los valores VIF estén bajo control antes de intentar interpretar los pesos. Un VIF alto puede generar "falsos negativos" (indicadores importantes que parecen no serlo) o cambios de signo absurdos (Hair et al., 2022).

5.3.3 Paso 3: Significación y Relevancia (El filtro de contribución)

Habiendo superado los filtros de convergencia y colinealidad, llegamos al núcleo del análisis formativo: determinar qué indicadores deben quedarse en el modelo y cuáles deben ser eliminados.

Para ello, utilizamos el procedimiento de **Bootstrapping** (con 5,000 submuestras) para evaluar dos dimensiones:

1. **El Peso Externo (w):** Representa la contribución *relativa* del indicador (su importancia en presencia de los otros).
2. **La Carga Externa (I):** Representa la contribución *absoluta* del indicador (su correlación bivariada con el constructo, sin competir con los otros).

A continuación, se presentan las **Herramientas Maestras de Decisión** que resumen los criterios técnicos y el protocolo exacto de depuración.

5.3.4 Resumen Ejecutivo de Métricas

La **Tabla 17** consolida todos los criterios técnicos necesarios para reportar la validación formativa, vinculando el dato estadístico con su implicación gerencial.

Tabla 17

Criterios, métricas y umbrales de validación formativa

Criterio de Evaluación	Métrica Clave	Umbral y Justificación	Implicación para la Toma de Decisiones
1. Validez de Contenido	Juicio de Expertos (VCE)	$I-CVI \geq 0.80$. Cada ítem debe tener respaldo teórico sólido.	Evita la "ceguera estratégica": asegura que no se omitan facetas críticas del negocio.
2. Validez Convergente	Análisis de Redundancia	Coefficiente Path ≥ 0.708 . (Explica el 50% de la varianza de la medida global).	Confirma que el índice construido representa la realidad. Si falla, el modelo no sirve para predecir.
3. Colinealidad	VIF (Variance Inflation Factor)	$VIF \geq 5$ (Crítico). $VIF < 3$ (Ideal).	Si hay colinealidad, no podemos saber qué palanca mover. Se deben eliminar las redundancias.
4. Significación del Peso	Valor t (Bootstrapping)	$t > 1.96$ (para $\alpha = 0.05$). Intervalo de Confianza no incluye el cero.	Determina si el indicador tiene un impacto real o es puro ruido estadístico.
5. Relevancia del Peso	Tamaño del Peso (beta)	Valores cercanos a ± 1 son fuertes; cercanos a 0 son débiles.	Identifica las variables más influyentes ("los pocos vitales") para priorizar la gestión.
6. La "Zona de Rescate"	Carga Externa (Loading)	≥ 0.50 . (Usado si el peso no es significativo).	Permite retener indicadores teóricamente valiosos, aunque estadísticamente compitan con otros.

Nota. Adaptado y ampliado de Hair et al. (2022).

5.3.5 Protocolo de Depuración: ¿Cuándo eliminar un indicador?

El error más común en modelos formativos es eliminar un indicador simplemente porque su peso no es significativo. Esto es incorrecto, ya que eliminar un indicador formativo cambia el significado del constructo (Bollen & Lennox, 1991).

Para evitar la eliminación injustificada, se debe seguir estrictamente la Matriz de Decisión presentada en la **Tabla 17**. Este protocolo actúa como una red de seguridad: si un indicador falla en su contribución relativa (peso), verificamos su contribución absoluta (carga) antes de descartarlo.

Tabla 18

Matriz de decisión para la eliminación o mantenimiento de indicadores formativos

Paso	Condición Evaluada	Resultado del Análisis	Decisión / Acción a tomar
1 (Testear valor t)	¿Es significativo el Peso Externo (w)?	Sí ($t > 1.96$)	MANTENER EL INDICADOR. Su contribución relativa es única y crítica.
		NO	Pasar al Paso 2. No eliminar todavía.
2	¿Es alta la Carga Externa (l)? (Evaluar correlación absoluta)	Sí (≥ 0.50)	MANTENER EL INDICADOR. Aunque compite con otros (peso bajo), su contribución absoluta es vital para la validez de contenido.
		NO (< 0.50)	Pasar al Paso 3.

Paso	Condición Evaluada	Resultado del Análisis	Decisión / Acción a tomar
3	¿Es significativa la Carga Externa?	SÍ (Significativa pero baja)	CONSIDERAR ELIMINACIÓN. Su contribución es débil. Solo consérvelo si la teoría lo hace indispensable.
		NO (No significativa)	ELIMINAR EL INDICADOR. No tiene contribución relativa ni absoluta. Es irrelevante empíricamente.

Nota. Adaptado de Hair et al. (2019).

5.4 **Diseño y validación del instrumento formativo: El Reto de la Convergencia**

La especificación de modelos formativos representa uno de los desafíos conceptuales más importantes en el diseño de una investigación mediante PLS-SEM. A diferencia de los modelos reflexivos, donde los indicadores son intercambiables y comparten una causa común, en los modelos formativos los indicadores son los "ladrillos" independientes que construyen el significado del constructo. Si eliminamos un indicador relevante, alteramos la naturaleza misma de la variable latente.

5.4.1 **El Desafío de la Validación:**

¿Por qué necesitamos medidas globales?

Dado que en los modelos formativos no se espera necesariamente que los indicadores correlacionen altamente entre sí (por ejemplo, la "estabilidad económica" no tiene por qué correlacionarse con la "visión de futuro", aunque ambos formen el

constructo "Desempeño"), el uso de métricas tradicionales de consistencia interna como el Alfa de Cronbach es metodológicamente incorrecto.

Entonces, ¿cómo validamos que nuestro conjunto de indicadores está capturando realmente el fenómeno que deseamos medir?

La respuesta reside en la Validez Convergente mediante Análisis de Redundancia. Este procedimiento, introducido por Chin (1998), prueba si el índice formativo (formado por la suma de ítems causales) correlaciona fuertemente con una medida global y reflexiva del mismo concepto.

Regla de Oro para el Diseño de Cuestionarios: Para ejecutar esta validación, el investigador está **obligado** a incluir en su instrumento una "Variable de Validación Alternativa". Frecuentemente, un único ítem global (Single Item) que resuma la esencia del constructo es suficiente (Cheah et al., 2018).

5.4.2 Caso Aplicado: Protocolo de Construcción del Modelo de Reputación

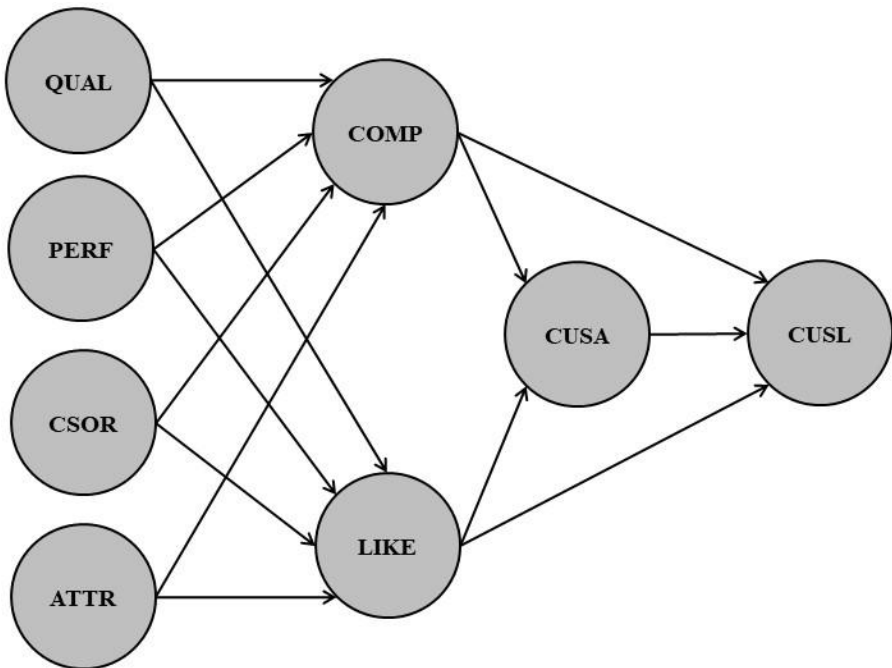
Para ilustrar este protocolo, utilizaremos el **Modelo de Reputación Corporativa**. Este modelo teórico asume que la reputación no es un rasgo monolítico que "emana" de la empresa, sino una construcción agregada formada por cuatro dimensiones

causales: **Calidad (QUAL), Desempeño (PERF), Responsabilidad Social (CSOR) y Atractivo (ATTR).**

Como se observa en la **Figura 9**, la dirección de las flechas va desde los indicadores hacia el constructo, denotando causalidad.

Figura 9

Modelo formativo de Reputación Corporativa



A continuación, la **Tabla 19** detalla los "ladrillos" (indicadores formativos) que construyen cada dimensión, mientras que la **Tabla 20**

presenta las **Medidas Globales** críticas que actuarán como "jueces externos" para el análisis de redundancia

Tabla 19

Constructos formativos

Constructo Formativo	Variable	Enunciado del Ítem (Indicador)
CALIDAD (QUAL)	qual_1	Los productos/servicios ofrecidos por [la empresa] son de alta calidad.
<i>(Calidad de productos y orientación al cliente)</i>	qual_2	[La empresa] es innovadora, en lugar de imitadora en su industria.
	qual_3	Los productos/servicios de [la empresa] ofrecen una buena relación calidad-precio.
	qual_4	Los servicios ofrecidos por [la empresa] son buenos.
	qual_5	Las preocupaciones de los clientes son muy tenidas en cuenta en [la empresa].
	qual_6	[La empresa] es un socio fiable para los clientes.
	qual_7	[La empresa] es una compañía digna de confianza.
	qual_8	Tengo mucho respeto por [la empresa].
	DESEMPEÑO (PERF)	perf_1
<i>(Desempeño económico y gerencial)</i>	perf_2	[La empresa] es económicamente estable.
	perf_3	El riesgo empresarial de [la empresa] es modesto comparado con sus competidores.
	perf_4	[La empresa] tiene potencial de crecimiento.
	perf_5	[La empresa] tiene una visión clara sobre su futuro.
RESPONSABILIDAD SOCIAL (CSOR)	csor_1	[La empresa] se comporta de manera socialmente consciente.
	csor_2	[La empresa] es franca al dar información al público.

Constructo Formativo	Variable	Enunciado del Ítem (Indicador)
	csor_3	[La empresa] tiene una actitud justa hacia los competidores.
	csor_4	[La empresa] se preocupa por la preservación del medio ambiente.
	csor_5	[La empresa] no solo se preocupa por los beneficios.
ATRACTIVO (ATTR)	attr_1	[La empresa] tiene éxito atrayendo empleados de alta calidad.
	attr_2	Podría verme trabajando en [la empresa].
	attr_3	Me gusta la apariencia física de [la empresa] (edificios, tiendas, etc.).

Tabla 20

Variables Globales para Análisis de Redundancia

Variable Global	Enunciado (Medida Resumen)
qual_global	Por favor, evalúe la calidad general de las actividades de [la empresa].
perf_global	Por favor, evalúe el desempeño general de [la empresa].
csor_global	Por favor, evalúe en qué medida [la empresa] actúa de manera socialmente consciente.
attr_global	Por favor, evalúe el atractivo general de [la empresa].

5.4.3 Procedimiento de Ejecución y Criterios de Decisión

Una vez recolectados los datos (incluyendo las variables globales de la Tabla 14), el análisis de redundancia se ejecuta siguiendo tres pasos estrictos:

1. **Modelado:** Configure en el software un modelo donde el constructo formativo (ej. `QUAL`) actúe como variable predictora (exógena) del ítem global único (ej. `qual_global`), que actuará como variable dependiente (endógena).
2. **Ejecución:** Corra el algoritmo PLS estándar.
3. **Evaluación (Criterio del Coeficiente Path):**
 - Examine el coeficiente path (beta) que conecta el constructo con su medida global.
 - **Umbral Crítico:** La correlación debe ser ≥ 0.708 . (Hair et al., 2022).
 - **Interpretación:** Este valor implica que el constructo formativo explica al menos el 50% de la varianza ($R^2 \geq 0.50$) de la medida global. Si se cumple, confirmamos que el índice formativo es una representación válida del concepto latente.

Nota Técnica: Para modelos basados en datos secundarios donde no es posible diseñar una pregunta global, se recomienda utilizar una variable proxy existente que mida teóricamente el mismo concepto (Houston, 2004).

Aquí tienes una redacción directa y clara, enfocada en el contexto metodológico (específicamente para la validación de modelos formativos o uso de datos secundarios).

5.5 Determinación y Uso de una Variable Proxy

Una variable **proxy** es una métrica sustituta que se utiliza cuando la variable de interés no puede medirse directamente o no fue incluida originalmente en el instrumento de recolección de datos.

Según **Houston (2004)**, en contextos donde no es posible diseñar una medida global específica (como en estudios basados en bases de datos secundarias o archivos históricos), el investigador debe identificar una variable existente que sea teóricamente equivalente al constructo en cuestión.

5.5.1 Cómo se determina (Selección Teórica)

Para determinar una proxy válido, no se busca una fórmula matemática, sino una equivalencia conceptual. La variable seleccionada debe cumplir dos condiciones:

- **Correlación Teórica:** Debe existir literatura previa que vincule fuertemente la proxy con el fenómeno estudiado.
- **Sensibilidad:** Debe variar de manera similar a como lo haría el constructo latente.

Ejemplo: Si estudiamos el constructo formativo "*Éxito Financiero*" y no tenemos una pregunta de encuesta sobre satisfacción financiera, podemos determinar como proxy el "Retorno sobre Activos (ROA)" o el "Margen de Beneficio Neto" extraído de los estados financieros de la empresa.

5.5.2 Cómo se calcula (Validación Estadística)

Una vez seleccionada, la proxy no se "calcula" en sí misma (ya es un dato existente), sino que se utiliza para **calcular la validez** del constructo formativo mediante el **Análisis de Redundancia**.

El procedimiento técnico en software (como SmartPLS o R) es:

1. **Configuración:** Establezca el constructo formativo como variable independiente (exógena).
2. **Vinculación:** Coloque la variable proxy (ej. ROA) como variable dependiente (endógena) de un solo ítem.
3. **Cálculo:** Ejecute el algoritmo PLS.
4. **Verificación:** Observe el **Coefficiente Path (beta)**.
 - Si $\beta \geq 0.708$, la proxy confirma que el constructo formativo es válido.
 - Esto indica que el constructo explica al menos el 50% ($R^2 \geq 0.50$) de la varianza de la variable proxy.

5.6 Validez convergente: el análisis de redundancia

A diferencia de los modelos reflexivos donde usamos AVE, la validez convergente en modelos formativos se evalúa mediante el análisis de redundancia. Este procedimiento prueba si el índice formativo (formado por indicadores o ítems causales como precio, calidad, etc.) correlaciona fuertemente con una medida global del mismo concepto.

La validez convergente en la evaluación de constructos formativos se aborda mediante el análisis de redundancia, un procedimiento esencial para verificar si el índice causal especificado captura adecuadamente el dominio conceptual pretendido. Este método, introducido por Chin (1998), se enfoca en el grado de correlación entre el constructo formativo y una medida alternativa y reflectiva del mismo concepto.

Para llevar a cabo el análisis, los investigadores deben incluir una variable de validación alternativa en su instrumento. Si bien este análisis tiene limitaciones reconocidas en términos de validez de criterio (Diamantopoulos, Riefler, y Roth, 2012; Sarstedt et al., 2016), la práctica común y aceptada es la flexibilidad. Cheah et al. (2018) demuestran que, frecuentemente, un único ítem global y de naturaleza reflectiva que resuma el concepto subyacente (ejm., "En general, considero que el valor ofrecido es alto") es suficiente. Para modelos basados en datos secundarios, se utiliza una variable existente que mida el mismo concepto (Houston, 2004).

El criterio estadístico para confirmar la validez convergente requiere una correlación sustancial entre el constructo formativo y su medida alternativa reflectiva. Según las directrices actualizadas de Hair et al. (2022), esta correlación debe ser igual o superior a 0.708. Este umbral es crucial, ya que implica que el constructo formativo explica más del 50% de la varianza ($R^2 \geq 0.50$) de la medida reflectiva, proporcionando una evidencia robusta de que el índice formativo es una representación válida del concepto latente.

Procedimiento:

1. Incluir en la encuesta un ítem global reflexivo (ej. "En general, estoy satisfecho con el servicio").
2. Modelar el constructo formativo como predictor de este ítem global.
3. Criterio: El Coeficiente Path (beta) debe ser ≥ 0.70 , lo que implica un $R^2 \geq 0.50$ (Cheah et al., 2018). Esto confirma que los indicadores formativos capturan al menos el 50% del significado del constructo.

Consecuencias e identificación de la colinealidad

La alta colinealidad tiene dos consecuencias principales que amenazan la validez de los resultados:

1. **Error estándar inflado y errores tipo II:** El alto grado de correlación entre predictores incrementa el error estándar de los pesos (β) de los indicadores. Esto, a su vez, reduce los valores t o p , aumentando la probabilidad de cometer un error de Tipo II (falso negativo), donde un indicador que realmente tiene una contribución significativa se estima como no significativo (Hair et al., 2019).
2. **Cambios de signo inesperados:** Niveles severos de colinealidad pueden inducir cambios de signo en los pesos de los indicadores. Por ejemplo, un indicador formativo que mide una faceta positiva

del rendimiento empresarial, como "la empresa está extremadamente bien gestionada", podría arrojar un peso negativo en la regresión del índice. Este resultado es contradictorio con las asunciones teóricas *a priori* y genera una gran confusión interpretativa, especialmente si la correlación bivariada entre el indicador y el constructo es positiva.

El factor de inflación de varianza (VIF) es la métrica estándar para diagnosticar la colinealidad. El valor VIF cuantifica cuánto se ha inflado la varianza del coeficiente de regresión de un indicador debido a la colinealidad con otros indicadores.

Criterios de diagnóstico y protocolo de revisión

Aunque el umbral tradicional para identificar problemas graves de colinealidad es $VIF > 5$, los investigadores deben ser cautelosos, ya que problemas pueden surgir incluso con valores de VIF por debajo de 3 (Becker et al., 2018; Mason y Perreault, 1991).

El protocolo de revisión debe seguir estos pasos:

1. **Diagnóstico inicial (VIF):** Calcule el VIF para cada indicador. Los valores $VIF > 5$ son indicativos de una colinealidad problemática, que exige una acción correctiva inmediata (Hair et al., 2022).

2. **Diagnóstico de signo (Correlación bivariada):** Si los pesos de los indicadores arrojan un signo inesperado (contrario a la teoría), el primer paso de verificación es comparar el signo del peso con el signo de la correlación bivariada entre el indicador y el constructo (o con la variable dependiente si el constructo es un predictor). Si el signo de la relación difiere del signo de la correlación, esto confirma que la colinealidad o la especificación del modelo es la causa del problema.

Estrategias de mitigación

Cuando se detectan problemas de colinealidad (VIF alto o cambios de signo), los investigadores deben tomar medidas correctivas apropiadas para reducir el nivel de intercorrelación y estabilizar las estimaciones. Las estrategias principales incluyen (Hair et al., 2022):

1. **Eliminación de indicadores:** Eliminar los indicadores con el **VIF** más alto y/o los que tienen pesos no significativos. Esta es la solución más directa, pero debe justificarse teóricamente, asegurando que la eliminación no comprometa la validez de contenido del constructo.
2. **Consolidación / combinación de indicadores:** Agrupar indicadores altamente colineales que midan facetas muy similares en un único sub-índice o medida agregada. Este índice

combinado puede luego usarse como un único predictor en el modelo formativo.

- 3. Desarrollo de un constructo de orden superior:** Reestructurar el modelo especificando el constructo formativo original como un constructo de segundo orden o más alto orden, donde los indicadores originales son agrupados en sub-dimensiones de primer orden, mitigando la colinealidad a nivel de las dimensiones más amplias.

5.7 Relevancia y significación estadística

La tercera etapa en la evaluación de constructos formativos se centra en la significación estadística y la relevancia (es decir, el tamaño) de los pesos de los indicadores (β). Los pesos son los coeficientes de regresión obtenidos al modelar el constructo formativo como una variable dependiente de sus indicadores, representando así la importancia relativa de cada ítem en la definición o formación del constructo.

Evaluación de la significación: Bootstrapping y valores críticos

El procedimiento de *bootstrapping* es la técnica estándar empleada para determinar la significación de los pesos en SEM basados en varianza (como PLS-SEM), ya que no requiere suposiciones de distribución paramétrica (Hair et al., 2014).

1. **Valores t:** El *bootstrapping* genera valores t para los pesos de los indicadores. Para determinar si un peso difiere significativamente de cero (es decir, si el indicador contribuye de manera única al constructo), el valor t observado debe compararse con los valores críticos de la distribución normal estándar:
 - **Nivel de significancia del 5% ($\alpha=0.05$):** Se requiere un valor $t \geq 1.96$ (prueba bidireccional).
 - **Otros niveles:** Los valores críticos comunes para la prueba bidireccional son 2.576 para $\alpha=0.01$ y 1.645 para $\alpha=0.10$.

2. **Intervalos de confianza (IC):** Alternativamente, la significación se puede evaluar utilizando los intervalos de confianza de *bootstrap*. El método de percentiles es el más recomendado, ya que ha demostrado superar a otros métodos en cobertura y equilibrio (Aguirre-Urreta y Rönkkö, 2018). Si el intervalo de confianza (ej., al 95%) para un peso no contiene el valor cero, el peso se considera estadísticamente significativo y el indicador se retiene. La inclusión del cero en el IC indica falta de significación y debe llevar a considerar la eliminación del indicador.

Cargas vs. Pesos: el criterio absoluto de contribución

Un peso no significativo no implica automáticamente un modelo de medida deficiente o la eliminación obligatoria del

indicador. Es crucial considerar la contribución absoluta del indicador, determinada por su carga (*loading*):

- **Peso (Contribución relativa):** Indica la importancia única del indicador en presencia de todos los demás. Se ve afectado por la colinealidad.
- **Carga (Contribución absoluta):** Mide la correlación simple entre el indicador y el constructo.

Criterio de retención dual (Cenfetelli y Bassellier, 2009):

Se sugiere que, si el peso del indicador no es significativo, se debe examinar su carga. Una carga del indicador ≥ 0.50 (o que sea estadísticamente significativa) indica que el indicador realiza una contribución absoluta suficiente a la formación del constructo, incluso si su contribución relativa (el peso) es débil o no significativa debido a la colinealidad.

Precauciones al eliminar indicadores formativos

La eliminación de indicadores formativos basándose únicamente en resultados estadísticos requiere extrema precaución por dos razones fundamentales:

1. **Dependencia del número de ítems:** El peso promedio de los indicadores disminuye a medida que aumenta el número de

ítems en el constructo. Los modelos formativos a menudo están inherentemente limitados en la cantidad de pesos que pueden ser simultáneamente significativos (Cenfetelli y Bassellier, 2009).

2. **Validez de contenido:** A diferencia de los modelos Reflexivos (donde los ítems son intercambiables), los indicadores formativos no lo son. La medición formativa requiere que los indicadores abarquen el dominio completo del constructo, tal como fue definido teóricamente. La eliminación, incluso de un solo indicador, puede reducir o alterar la validez de contenido y cambiar el significado conceptual del constructo (Bollen y Diamantopoulos, 2017).

Evaluación de la relevancia (tamaño del peso)

Tras confirmar la significación estadística, se examina la relevancia del indicador, que se determina por el tamaño estandarizado del peso. Los pesos estandarizados varían entre -1 y $+1$:

- Los pesos cercanos a $+1$ o -1 indican relaciones fuertes (positivas o negativas, respectivamente), señalando que el indicador tiene una gran importancia gerencial.
- Los pesos cercanos a “0” indican una relación relativamente débil o una contribución marginal, incluso si es estadísticamente significativa.

Esta evaluación ayuda a los investigadores a priorizar qué elementos del constructo (ej., características del producto, factores de servicio) tienen el mayor impacto causal para la toma de decisiones empresariales.

5.8 Referencias científicas sobre modelos formativos

1. Guenther, P., et al. (2023). Mejorar el uso de PLS-SEM para la investigación de constructos formativos en negocios y marketing. *Industrial Marketing Management*, 112, 1–15.
<https://www.sciencedirect.com/science/article/pii/S0019850123000445>
 · Revisan aplicaciones actuales del PLS-SEM en la investigación empresarial, enfatizando la correcta especificación y validación de modelos formativos en estudios de negocios y marketing.
2. Diamantopoulos, A., & Winklhofer, H. (2001). Index construction with formative indicators: An alternative to scale development. *Journal of Marketing Research*, 38(2), 269-277.
https://www.researchgate.net/publication/23776126_Formative_Versus_Reflective_Measurement_Models_Two_Applications_of_Formative_Measurement
 · Artículo clásico que fundamenta las diferencias, ventajas y cuestiones técnicas en la especificación de modelos formativos frente a los Reflexivos en SEM.
3. Hair, J.F., Ringle, C.M., & Sarstedt, M. (2017). Evaluación de modelos de medición formativa. En *Partial Least Squares Structural Equation Modeling (PLS-SEM) Using R*, Springer.
https://link.springer.com/chapter/10.1007/978-3-030-80519-7_5
 · Explica cómo construir, especificar y validar modelos formativos en SEM utilizando PLS, con ejemplos aplicados a empresas.

4. Levy, J., & Varela, J. (2006). Modelos de medición reflectiva y formativa en la investigación empresarial. *Papeles del Psicólogo*, 27(3), 167-175. <https://www.papelesdelpsicologo.es/pdf/1794.pdf>
· Comparan modelos de medida reflectiva y formativa demostrando implicaciones prácticas en la medición de constructos empresariales.
5. Hair, J.F., Anderson, R.E., Tatham, R.L., & Black, W.C. (2007). *Multivariate Data Analysis*. Pearson Education. (Referencia de uso de PLS-SEM para medidas formativas).
<https://www.periodicos.capes.gov.br/index.php/acervo/buscador.html?task=detalhes&id=W2948706555>
· Incorpora modelos formativos y su validación en análisis SEM aplicado a empresas.
6. Mendez, M., & Guzmán, A. (2020). Modelo SEM basado en valores organizacionales y capital humano en empresas ecuatorianas. *Retos*, 19(1), 11-25.
<https://retos.ups.edu.ec/index.php/retos/article/view/19.2020.01>
· Aplica un modelo SEM con variables formativas para analizar la influencia del capital humano y valores organizacionales en empresas.
7. Ringle, C.M., Sarstedt, M., Mitchell, R., & Gudergan, S.P. (2020). Partial Least Squares Structural Equation Modeling in HRM research: Models, methods, and measures. *The International Journal of Human Resource Management*, 31(12), 1617-1643.
<https://www.mdpi.com/2076-3387/9/4/85>
· Desarrolla la validez y aplicación de modelos formativos en SEM para recursos humanos y gestión empresarial.
8. Barringer, B.R., & Bluedorn, A.C. (1999). The relationship between corporate entrepreneurship and strategic management. *Strategic Management Journal*, 20(5), 421-444.
https://www.researchgate.net/publication/239551674_The_Relationship_Between_Corporate_Entrepreneurship_and_Strategic_Management

- Utiliza modelos formativos para medir el emprendimiento corporativo y su relación con estrategias empresariales.
9. Valdivieso, E. (2013). Medición formativa de competencias empresariales: Aplicaciones SEM. *International Journal of Business*, 18(2), 123-145.
http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-74672018000100130
 - Explora la aplicación de modelos formativos para evaluar competencias y desempeño en empresas mediante SEM.
 10. Benito Hernández, S., & Platero Jaime, M. (2025). Explorando la relación entre la formación y el desempeño empresarial mediante modelos formativos SEM. *Revista de Ciencias Económicas y Empresariales*, 12(2), 206–229.
http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S2739-00632025000202062
 - Caso práctico del uso de SEM con indicadores formativos para analizar la formación y el desempeño en microempresas en Lima.

Referencias

- Bollen, K., & Lennox, R. (1991). Conventional wisdom on measurement: A structural equation perspective. *Psychological Bulletin*, *110*(2), 305-314. <https://doi.org/10.1037/0033-2909.110.2.305>
- Campos, L. A. G. (2020). *Modelo SEM basado en valores organizacionales y capital... Revista (ejemplo de aplicación en contexto peruano)*. <https://www.redalyc.org/journal/5045/504562644001/>
- Cheah, J. H., Sarstedt, M., Ringle, C. M., Ramayah, T., & Ting, H. (2018). Convergent validity assessment of formatively measured constructs in PLS-SEM: On the necessity of the redundancy analysis. *International Journal of Contemporary Hospitality Management*, *30*(11), 3241-3260. <https://doi.org/10.1108/IJCHM-10-2017-0649>
- Cheung, G. W. (2024). Reporting reliability, convergent and discriminant validity with structural equation modeling: A review and best-practice recommendations. *Asia Pacific Journal of Management*. <https://doi.org/10.1007/s10490-023-09871-y>
- Chin, W. W. (1998). The partial least squares approach for structural equation modeling. En G. A. Marcoulides (Ed.), *Modern methods for business research* (pp. 295-336). Lawrence Erlbaum Associates Publishers.
- Diamantopoulos, A. (1999). Export performance measurement: Reflective versus formative indicators. *International Marketing Review*, *16*(4/5), 444-452.
- Diamantopoulos, A., Riefler, P., & Roth, K. P. (2008). Advising on the use of formative measures in international marketing. *International Marketing Review*, *25*(6), 675-697. <https://doi.org/10.1108/02651330810915583>

- Diamantopoulos, A., Riefler, P., & Roth, K. P. (2012). Advancing formative measurement operationalization and validation. *Journal of Business Research*, 65(11), 1632-1638. <https://doi.org/10.1016/j.jbusres.2011.10.007>
- 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/10.2307/3151312>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2017). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (2.^a ed.). SAGE Publications.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., Sarstedt, M., & Thiele, K. O. (2022). Mirror, mirror on the wall: A review and guidelines for the use of formative measurement. *Applied Psychological Measurement*, 46(4), 283-311.
- 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(1), 115-135. <https://doi.org/10.1007/s11747-014-0403-8>
- Houston, M. B. (2004). The effects of relationship-specific knowledge on switching costs and perceived relationship quality in customer-salesperson relationships. *Journal of the Academy of Marketing Science*, 32(4), 447-464.
- 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://doi.org/10.1086/376806>
- Mackenzie, S. B., Podsakoff, P. M., & Jarvis, C. B. (2005). The problem of measurement model misspecification in behavioral and organizational research and some recommended solutions. *Journal of*

Applied Psychology, 90(4), 717-732. <https://doi.org/10.1037/0021-9010.90.4.710>

McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, 23(3), 412-433. <https://doi.org/10.1037/met0000144>

Petter, S., Straub, D., & Rai, A. (2007). Specifying formative constructs in information systems research. *MIS Quarterly*, 31(4), 623-656. <https://doi.org/10.2307/25148814>

Sarstedt, M., Hair, J. F., Ringle, C. M., Homburg, C., Gudergan, S. P., & Christian, R. (2016). Estimation issues with formative measurement: A two-stage solution using PLS-SEM. *Journal of Business Research*, 69(1), 154-160. <https://doi.org/10.1016/j.jbusres.2015.03.042>

Wold, H. (1982). Soft modeling: The basic design and some extensions. En K. G. Jöreskog & H. Wold (Eds.), *Systems under indirect observation: Causality, structure, prediction* (pp. 1-54). North-Holland.

CAPITULO VI

MODELO ESTRUCTURAL:

EVALUACIÓN DE RELACIONES, EFECTOS Y PREDICCIÓN

Este capítulo aborda la evaluación del modelo estructural (inner model), poniendo énfasis en el análisis de las relaciones causales entre constructos, los coeficientes de ruta, la significancia mediante *bootstrapping*, el poder explicativo (R^2), el tamaño del efecto (f^2) y la relevancia predictiva a través de PLSpredict. Se propone una secuencia integral que parte del diagnóstico de colinealidad y culmina con la interpretación estratégica de los resultados.

El enfoque promueve un análisis orientado al futuro, subrayando la importancia de la predicción como criterio central en investigaciones aplicadas en negocios. Se incorporan prácticas contemporáneas que destacan la necesidad de reportes reproducibles, descriptivos y estratégicos para la comunidad científica.

6.1 Propósito y fundamento

El modelo estructural en PLS-SEM se orienta fundamentalmente al análisis causal-predictivo (Sarstedt et al., 2019). Su naturaleza se asemeja a un conjunto de ecuaciones de regresión múltiple, donde las variables latentes (constructos) actúan como predictores y criterios a la vez (Hair et al., 2011; Ringle et al., 2010; Sarstedt et al., 2011).

- **Orientación predictiva:** A diferencia de los métodos basados en covarianza (CB-SEM) que se centran en el ajuste del modelo a la matriz de covarianza, PLS-SEM prioriza la varianza explicada (R^2) en las variables endógenas y la relevancia predictiva (Q^2 o PLSpredict), lo que lo hace ideal para la exploración de teorías o la predicción de resultados clave en entornos complejos o con conocimiento teórico limitado (Hair et al., 2022).
- **Fundamento teórico:** Las relaciones causales (flechas) no son arbitrarias. Deben estar justificadas a partir de teorías existentes (ej., teoría del comportamiento) o evidencia empírica previa. La evaluación del modelo estructural es, en esencia, la confrontación de la teoría con los datos empíricos
- **Flexibilidad metodológica:** PLS-SEM es una técnica basada en la varianza que no impone supuestos paramétricos rigurosos, como la normalidad en la distribución de los datos, ofreciendo mayor flexibilidad en la modelación (Martínez, 2015).

6.1.1 Relación con la teoría subyacente

El modelo estructural es la traducción directa de la teoría estructural que el investigador busca probar.

- **Comprobación de hipótesis:** El objetivo es comprobar si los coeficientes de sendero son estadísticamente significativos (a través del procedimiento de *bootstrapping* y el valor t) y si tienen el signo y la magnitud esperados según la teoría. La validación del modelo estructural es, por tanto, la prueba empírica de la teoría propuesta.

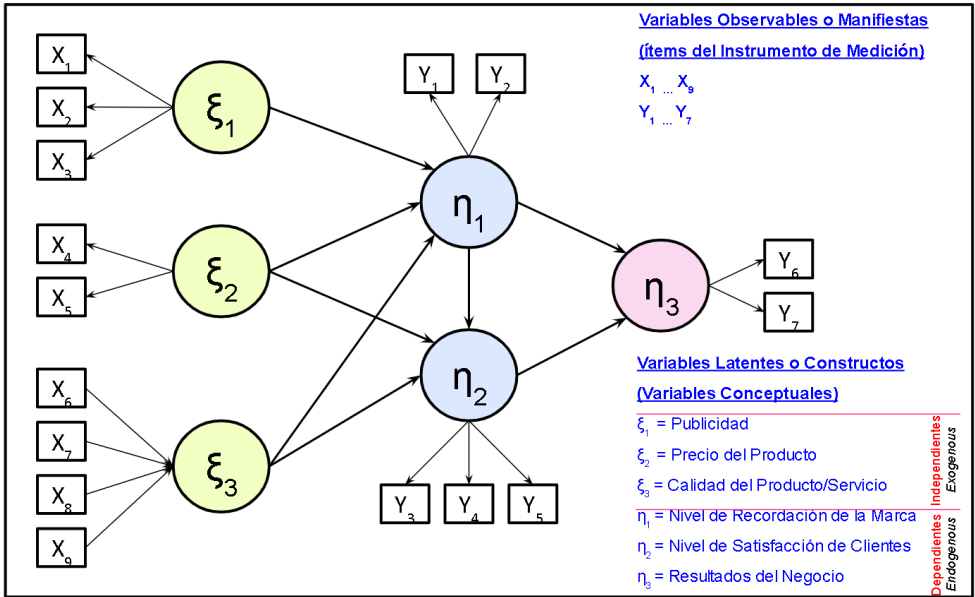
Es vital notar que la validación de las medidas (modelo de medición) debe preceder siempre a la evaluación del modelo estructural, asegurando que los constructos sean fiables y válidos antes de probar las relaciones entre ellos.

Ejemplos de aplicación

PLS-SEM es una herramienta muy popular en las ciencias empresariales debido a su capacidad para manejar modelos complejos y muestras pequeñas o no normales, enfocándose en la predicción y el desarrollo teórico.

Figura 10

Modelo conceptual SEM



Fuente: Saravia (2024) Universidad del Pacifico PIE

La Figura 10. Ejemplo de especificación teórica en un escenario empresarial complejo. El diagrama demuestra la versatilidad del PLS-SEM para articular múltiples capas de análisis (variables exógenas, mediadoras y dependientes) en una sola red nomológica, permitiendo al investigador visualizar la arquitectura predictiva completa del estudio antes de la estimación estadística.

Conexión práctica

🔗 El Contexto Importa: Aplicando SEM en Mercados Emergentes

No se deben importar modelos teóricos de países desarrollados sin validarlos en nuestro contexto local. Las variables culturales cambian las reglas del juego.

En el Caso de Estudio 8 (Capítulo IX), realizado en Ecuador, se demuestra cómo la variable "Confianza" actúa como una barrera mucho más fuerte para el comercio electrónico que en Europa. Este estudio es un modelo a seguir para investigadores que deseen replicar teorías globales en entornos latinoamericanos. Véase el análisis de barreras y motivadores en la Sección 9.8.

6.2 Colinealidad en el modelo estructural

El análisis de la colinealidad es un paso esencial en la evaluación del Modelo Estructural (*Inner Model*). La colinealidad surge cuando dos o más constructos predictores dentro de una misma regresión del modelo estructural están altamente correlacionados (Hair et al., 2011).

La presencia de colinealidad puede sesgar las estimaciones de los coeficientes de sendero (β) e inflar sus errores estándar, lo que reduce la potencia estadística para detectar relaciones significativas y aumenta el riesgo de errores de Tipo II (falsos negativos).

Métrica y criterios

Se utiliza el Factor de Inflación de la Varianza (VIF) calculado sobre los puntajes de los constructos latentes (no sobre los indicadores).

Tabla 21

Criterios para la colinealidad

Rango de VIF	Interpretación del Problema	Acción Recomendada
VIF < 3	Ideal	Proceder con el análisis. Indica independencia entre predictores.
VIF 3 - 5	Aceptable	Proceder con precaución. Verificar consistencia teórica.
VIF >= 5	Crítico	Detener el análisis. Existe redundancia severa. Se debe eliminar un predictor o fusionar constructos colineales.

Fuente: Hair et al. (2019).

La gestión efectiva de la colinealidad asegura que los coeficientes de sendero (β) representen con precisión la contribución única de cada constructo predictor al constructo criterio.

6.3 Evaluación de las relaciones hipotetizadas

Una vez asegurada la ausencia de colinealidad, se evalúa el tamaño y la significancia de los Coeficientes Path (beta). Estos representan las hipótesis causales del estudio.

6.3.1 Procedimiento de Bootstrapping

PLS-SEM no asume normalidad en los datos, por lo que no puede usar pruebas paramétricas tradicionales. En su lugar, utiliza el Bootstrapping (remuestreo con reemplazo, típicamente 5,000 o 10,000 submuestras) para estimar la significancia estadística.

6.3.2 Criterios de decisión

La evaluación debe basarse en tres pilares:

1. Significancia estadística (p y t):

- **Valor t:** Debe ser > 1.96 para un nivel de confianza del 95% (prueba de dos colas).
- **Valor p:** Debe ser < 0.05 .

2. Intervalos de confianza (Bias-Corrected CI):

- Esta es la métrica más robusta recomendada actualmente.
- **Regla:** Si el intervalo de confianza (ej. [2.5%, 97.5%]) NO incluye el cero, la hipótesis se acepta. Si cruza el cero (ej. de -0.1 a +0.2), la relación no es significativa.

3. Relevancia práctica (magnitud de beta):

- Un coeficiente puede ser significativo pero trivial (ej. $\beta = 0.05$). Se buscan coeficientes sustanciales (cerca de ± 0.20 o más) que denoten un impacto gerencial real.

6.4 Poder explicativo (R^2) y tamaño del efecto (f^2)

6.4.1 Coeficiente de determinación (R^2)

Mide la proporción de varianza de la variable endógena explicada por el modelo.

- **Criterios (Marketing/Negocios):**
 - $R^2 \approx 0.75$: Sustancial.
 - $R^2 \approx 0.50$: Moderado.
 - $R^2 \approx 0.25$: Débil.

6.4.2 Tamaño del efecto (f^2)

El R^2 nos dice *cuánto* explicamos en total, pero el f^2 nos dice cuánto aporta cada predictor individualmente. Se calcula excluyendo un predictor del modelo y viendo cuánto cae el R^2 .

- **Criterios (Cohen, 1988):**
 - $f^2 \geq 0,02$: Efecto Pequeño.

- $f^2 \geq 0.15$: Efecto Mediano.
- $f^2 \geq 0.35$: Efecto Grande.
- *Interpretación:* Si un predictor tiene un $f^2 < 0,02$, su contribución explicativa es trivial, incluso si es significativo.

6.5 Relevancia predictiva (Q^2 y PLSpredict)

Siguiendo las directrices modernas de Shmueli et al. (2019), no basta con explicar R^2); el modelo debe ser capaz de predecir nuevos casos.

6.5.1 Procedimiento PLSpredict

Esta técnica divide la muestra en entrenamiento y prueba (k-fold cross-validation) para evaluar el error de predicción.

Criterio de Decisión (RMSE)

Se compara el error (RMSE) del modelo PLS contra un modelo de regresión lineal simple (LM - Linear Model).

- **Poder Predictivo Alto:** PLS tiene menor error que LM en todos los indicadores.
- **Poder Predictivo Medio:** PLS tiene menor error en la mayoría de los indicadores.

- **Poder Predictivo Bajo:** PLS tiene menor error en la minoría.
- **Sin Poder Predictivo:** PLS tiene mayor error que LM en todos los casos.

Resumen de métricas de evaluación

Tabla 22

Checklist de evaluación del Modelo Estructural

Paso	Criterio	Umbral / Regla de Decisión
1. Colinealidad	VIF (Inner Model)	< 3 (Ideal), < 5 (Límite).
2. Hipótesis	Signos y Dirección	Coherentes con la teoría.
	Significancia	$p < 0.05$; $t > 1.96$; IC no cruza el cero.
3. Explicación	R^2 (Varianza)	0.25 (Débil), 0.50 (Mod.), 0.75 (Fuerte).
	f^2 (Tamaño Efecto)	> 0.02 (Pequeño), > 0.15 (Medio), > 0.35 (Grande).
4. Predicción	PLSpredict ($Q^2_{predict}$)	$RMSE_{PLS} < RMSE_{LM}$ en la mayoría de ítems.

Fuente: Elaboración basada en Hair et al. (2022) y Shmueli et al. (2019).

6.6 Significancia y relevancia de relaciones estructurales

El paso final en la validación del Modelo Estructural es evaluar la significancia estadística y la relevancia práctica de los coeficientes de sendero (β o *path coefficients*). Este proceso determina si las hipótesis causales propuestas entre los constructos latentes están empíricamente soportadas.

1. El Procedimiento de *Bootstrapping*

Para probar la significancia de las relaciones estructurales, se utiliza el procedimiento de *bootstrapping*. Este procedimiento no paramétrico permite obtener los errores estándar y los valores t (o *t-statistics*) para los coeficientes de sendero sin depender de los supuestos de distribución de los datos, lo cual es vital en PLS-SEM (Hair et al., 2019).

Al ejecutar el *bootstrapping*, los resultados clave se obtienen y se interpretan de la siguiente manera:

Tabla 23

Métrica Bootstrapping

Métrica de Salida	Definición y Función
Muestra Original (Original Sample)	El coeficiente de sendero (β) estimado a partir de los datos originales. Mide la magnitud de la relación.
Media de la Muestra (Sample Mean)	El coeficiente de sendero promedio obtenido de las submuestras de bootstrap. Suele ser similar a la Muestra Original.
Error Estándar (DE) (Standard Deviation)	La desviación estándar de la distribución de bootstrap. Cuantifica la fluctuación muestral y es crucial para el cálculo del valor t.
Estadística T (T-Statistics)	Mide cuántas desviaciones estándar está el coeficiente estimado de cero. Es la métrica inferencial central para probar la hipótesis nula ($\beta = 0$).
Valor (P-Value)	El nivel de significancia marginal; representa la probabilidad de obtener el valor t observado (o más extremo) si la hipótesis nula fuera cierta.

2. Criterios para la significancia estadística

La significancia de una relación estructural puede evaluarse utilizando el valor t, el valor p, o los intervalos de confianza.

Tabla 24

Significancia estadística

Criterio Estadístico	Nivel de Significancia (α)	Umbral Mínimo	Decisión
Estadística T (Prueba Bidireccional)	0.05		t
Estadística T (Prueba Unilateral)	0.05	$t \geq 1.645$	Rechazar H0. Relación significativa en la dirección esperada.
Valor (Cualquier prueba)	≤ 0.05	$p \leq 0.05$	Rechazar H0. Se apoya la hipótesis propuesta.

Un valor 0.05 o un valor t superior a 1.96 (bidireccional) indica que el coeficiente de sendero es estadísticamente significativo; es decir, la relación es improbable que se deba al azar y se valida la hipótesis propuesta.

3. Evaluación de la Relevancia (Magnitud del Coeficiente)

La relevancia práctica o magnitud de la relación se evalúa directamente a partir del coeficiente de sendero (Muestra Original). Los coeficientes de sendero estimados oscilan típicamente entre -1 y $+1$.

- **Asociación fuerte:** Coeficientes cercanos a +1 o -1 indican una asociación fuerte y determinante entre los constructos.
- **Asociación débil:** A medida que los coeficientes se acercan a 0, la conexión estructural se debilita. Los valores bajos cercanos a cero, en particular, rara vez son estadísticamente significativos (Hair et al., 2019).

La interpretación del signo (positivo o negativo) debe ser consistente con la teoría subyacente. Un coeficiente β significativo con un valor alto demuestra que el constructo predictor es una **palanca causal importante** para explicar el constructo endógeno.

Coefficiente de determinación (R^2)

El Coeficiente de Determinación (R^2) es una métrica clave utilizada en la evaluación del Modelo Estructural (*Inner Model*) de PLS-SEM para medir su poder explicativo (Hair et al., 2019). Esta medida indica la proporción de la varianza de una variable latente endógena (dependiente) que es explicada o predicha por sus variables latentes exógenas (independientes) en el modelo (McKelvey y Zavoina, 1975).

Tamaño del Efecto (f^2)

Mientras que el R^2 evalúa el poder explicativo total del modelo, el tamaño del efecto f^2 evalúa la contribución individual de

cada constructo exógeno (predictor) al R^2 de una variable latente endógena.

El cálculo se realiza mediante el cambio en el R^2 cuando un predictor específico se excluye del modelo. Según Hair et al. (2022), esta métrica es crucial para distinguir entre significancia estadística (valor p) y relevancia sustantiva. Es posible que un coeficiente path sea significativo, pero que su aporte real a la explicación del fenómeno sea trivial.

Criterios de evaluación:

Se utilizan los umbrales clásicos establecidos por Cohen (1988) para las ciencias del comportamiento:

- $f^2 \geq 0.02$: efecto pequeño.
- $f^2 \geq 0.15$: efecto mediano.
- $f^2 \geq 0.35$: efecto grande.
- $f^2 < 0.02$: efecto nulo o trivial.

Implicación práctica: Si un predictor muestra un valor $p < 0.05$ (significativo) pero un $f^2 < 0.02$, el investigador debe concluir que, aunque la relación existe, su impacto en la variable dependiente es despreciable para la toma de decisiones gerenciales.

Relevancia predictiva fuera de muestra (PLSpredict)

El enfoque tradicional de evaluación basado solo en métricas explicativas (R^2) y el criterio de *blindfolding* (Q^2) ha sido

superado en la literatura reciente. Shmueli et al. (2019) argumentan que un modelo puede explicar bien los datos existentes (ajuste) pero fallar estrepitosamente al predecir nuevas observaciones (sobreajuste).

Para abordar esto, el estándar actual es el algoritmo PLSpredict. Este método utiliza procedimientos de validación cruzada (*k-fold cross-validation*) dividiendo la muestra en conjuntos de entrenamiento y prueba para evaluar el error de predicción real.

Procedimiento de Evaluación (RMSE)

La evaluación se centra en comparar el error de predicción del modelo PLS ($RMSE_{PLS}$) frente a un punto de referencia ingenuo, típicamente un Modelo Lineal ($RMSE_{LM}$). La lógica es simple: si el modelo PLS complejo no puede predecir mejor que una regresión lineal simple, su utilidad predictiva es cuestionable (Hair et al., 2019).

Criterios de Decisión

Basado en la comparación de los errores (RMSE) para cada indicador de la variable dependiente, Shmueli et al. (2019) proponen la siguiente escala de poder predictivo:

Tabla 25

Directrices de evaluación de PLSpredict

Resultado de la Comparación (RMSEPLS vs RMSELM)	Nivel de Poder Predictivo
El error de PLS es menor que el de LM en todos los indicadores.	Alto
El error de PLS es menor que el de LM en la mayoría de los indicadores.	Medio
El error de PLS es menor que el de LM en la minoría de los indicadores.	Bajo
El error de PLS es mayor que el de LM en todos los indicadores.	Sin Poder Predictivo

Fuente: Adaptado de Shmueli et al. (2019).

Tabla 26

Checklist consolidado de evaluación

Paso	Criterio Analítico	Métrica Clave	Umbral / Regla de Decisión
1. Colinealidad	Ausencia de sesgo por correlación	VIF (Inner Model)	< 3 (Ideal), < 5 (Aceptable).
2. Hipótesis	Significancia Estadística	Bootstrapping (p, t, IC)	$p < 0.05$; $t > 1.96$; IC no cruza el cero.
	Relevancia Práctica	Coefficiente Path (beta)	Magnitud sustancial (ej. > 0.20) y signo coherente con teoría.
3. Explicación	Varianza Explicada Total	R ²	0.25 (Débil), 0.50 (Mod.), 0.75 (Fuerte).
	Contribución Individual	Tamaño del Efecto (f ²)	> 0.02 (Pequeño), > 0.15 (Medio), > 0.35 (Grande).
4. Predicción	Precisión Fuera de Muestra	PLSpredict	RMSEPLS < RMSELM en la mayoría de los indicadores.

Fuente: Elaboración propia basada en Hair et al. (2022) y Shmueli et al. (2019).

6.7 Referencias científicas sobre Modelo Estructural

1. Gefen, D., Straub, D., & Boudreau, M.C. (2000). Structural Equation Modeling and Regression: Guidelines for Research Practice. Communications of the Association for Information Systems, 4(7). <https://www.semanticscholar.org/paper/Structural-Equation-Modeling-and-Regression:-for-Gefen-Straub/3787715114e286042aac4fd9b612114c226c6fe9>
· Presenta directrices detalladas sobre el uso correcto de modelos estructurales (Inner Model) y regresión en investigación en administración e información empresarial, con ejemplos prácticos en ciencias empresariales.
2. Hair, J.F., Ringle, C.M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. Journal of Marketing Theory and Practice, 19(2), 139-152.
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1954735
Explica la metodología Partial Least Squares Structural Equation Modeling (PLS-SEM) y su uso para analizar relaciones latentes y complejas en contextos empresariales y de mercadotecnia.
3. Henseler, J., Ringle, C.M., & Sinkovics, R.R. (2009). The use of partial least squares path modeling in international marketing. Advances in International Marketing, 20, 277-319.
https://research.manchester.ac.uk/files/33613852/FULL_TEXT.PDF
Describe aplicaciones y fortalezas del Inner Model en el modelado PLS-SEM, con referencia específica a investigaciones de marketing internacional.
4. Ramírez-Aldana, R., & Palacios-Marqués, D. (2020). Digital innovation and performance: Inner model application in SMEs. Technological Forecasting and Social Change, 163, 120498.
<https://www.periodicos.capes.gov.br/index.php/acervo/buscarador.html?task=detalhes&id=W2948706555>
Investiga cómo la innovación digital afecta el desempeño

organizacional mediante el uso del Inner Model en pequeñas y medianas empresas.

5. Bollen, K.A. (1989). Structural Equations with Latent Variables. Wiley. <https://content.e-bookshelf.de/media/reading/L-806416-d104b86f34.pdf>
Libro de referencia clásica sobre teoría y aplicaciones del Inner Model con variables latentes, incluyendo ejemplos de ciencias empresariales.
6. Sarstedt, M., & Mooi, E. (2019). A Concise Guide to Market Research: The Process, Data, and Methods Using SEM. Springer. <https://educons.edu.rs/wp-content/uploads/2020/05/2019A-Concise-Guide-To-Market-Research.pdf>
Expone el proceso de investigación de mercados con énfasis en el uso de SEM para modelar relaciones causales y estructurales en administración y empresas.
7. Cepeda, G. & Roldán, J.L. (2004). Aplicando modelos de ecuaciones estructurales en ciencias sociales. Papeles del psicólogo, 25(1), 101-113. <https://www.papelesdelpsicologo.es/pdf/1794.pdf>
Revisa los fundamentos y aplicaciones prácticas del Inner Model, adaptándolos a contextos empresariales y organizacionales en español.
8. Vargas Martínez, M.R. (2024). Evaluación del emprendimiento universitario en República Dominicana mediante modelo Inner Model PLS-SEM. Universidad de Córdoba. <https://helvia.uco.es/bitstream/handle/10396/27728/2024000002829.pdf?sequence=1&isAllowed=y>
Tesis doctoral que utiliza el Inner Model para analizar relaciones y efectos sobre el emprendimiento universitario desde una perspectiva empresarial.
9. Díaz-Jaimes, M.D.P. & Ortiz Pimiento, N.R. (2012). Revisión de modelos de madurez: Estrategia para gestionar organizaciones. Revista UIS Ingenierías, 11(2), 55-72.

<https://revistas.uis.edu.co/index.php/revistauisingenierias/article/view/55-72/4565>

Analiza y compara modelos estructurales para la madurez y evaluación del desempeño en empresas, usando Inner Models aplicados a manufactura.

10. Schumacker, R. E., & Lomax, R. G. (2010). Structural Equation Modeling: A Second Course. (PDF - Academia.edu) https://www.academia.edu/13420074/Structural_equation_modeling_A_second_generation_multivariate_analysis

Presenta ejemplos y técnicas avanzadas de SEM (Inner Model) para su uso en ciencias empresariales, con casos prácticos y simulaciones.

Referencias

- 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/10.2307/3151312>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A primer on partial least squares structural equation modeling (PLS-SEM)* (3rd ed.). Sage.
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139-152. <https://doi.org/10.2753/MTP1069-6679190202>
- 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://doi.org/10.1108/EBR-11-2018-0203>
- 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://doi.org/10.1086/376806>
- Martínez Ávila, M., & Fierro Moreno, E. (2018). Aplicación de la técnica PLS-SEM en la gestión del conocimiento: Un enfoque técnico práctico / Application of the PLS-SEM technique in Knowledge Management: a practical technical approach. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 8(16), 130-164. <https://doi.org/10.23913/ride.v8i16.336>

- Martínez, F. J. (2015). El gobierno corporativo y la responsabilidad social corporativa en el sector bancario: Papel del consejo de administración. *Economía Española*, 27, 50-67. <https://doi.org/10.1016/j.iedee.2015.01.001>
- Ringle, C. M., Wende, S., & Will, A. (2010). Finite Mixture Partial Least Squares Analysis: Methodology and Numerical Examples. En V. Esposito Vinzi, W. W. Chin, J. Henseler, & H. Wang (Eds.), *Handbook of Partial Least Squares: Concepts, Methods and Applications* (pp. 195-218). Springer. https://doi.org/10.1007/978-3-540-32827-8_9
- Sarstedt, M., Becker, J.-M., Ringle, C. M., & Schwaiger, M. (2011). Unobserved Heterogeneity in Structural Equation Models: A Comparison of FIMIX-PLS with Standard Segmentation Approaches. *International Journal of Research in Marketing*, 28(3), 231-241. <https://doi.org/10.1016/j.ijresmar.2011.04.001>
- Sarstedt, M., Hair, J. F., Nitzl, C., Ringle, C. M., & Howard, M. C. (2020). Beyond a tandem analysis of SEM and PROCESS: Use of PLS-SEM for mediation analyses! *International Journal of Market Research*, 62(3), 288-299. <https://doi.org/10.1177/1470785320915686>
- Sarstedt, M., Ringle, C. M., & Hair, J. F. (2019). Prediction-oriented model evaluation in PLS-SEM: Guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322-2347. <https://doi.org/10.1108/EJM-02-2019-0189>

CAPITULO VII

MODELOS INTERACCIONALES:

MEDIACIÓN Y MODERACIÓN EN SEM

Este capítulo integra los análisis de mediación y moderación como estrategias fundamentales para comprender procesos y condiciones bajo las cuales se producen los efectos causales entre constructos. Se explican los fundamentos teóricos, los criterios para detectar mediación y los procedimientos para estimar efectos indirectos mediante bootstrapping. En cuanto a la moderación, se examinan los tipos de interacción, los supuestos estadísticos, los riesgos analíticos y las medidas preventivas durante la preparación de datos.

El capítulo finaliza con lineamientos de reporte estandarizado para publicaciones científicas, considerando tanto el rigor académico como su utilidad práctica para gestores empresariales que necesitan interpretar implicancias causales complejas.

ANÁLISIS DE MEDIACIÓN EN SEM

La investigación en ciencias empresariales se enfoca en desentrañar las complejas relaciones causales que impulsan el rendimiento, la satisfacción del cliente y la ventaja competitiva. Si bien la identificación de un vínculo directo entre dos variables (por ejemplo, el liderazgo y el desempeño) es valiosa, se vuelve insuficiente para una comprensión estratégica profunda. El verdadero desafío reside en responder al "cómo" y al "por qué" de dicha relación. Aquí es donde el análisis de mediación emerge como una herramienta metodológica indispensable.

7.1 Contexto teórico y valor de la mediación causal

La mediación, en el contexto del Modelado de Ecuaciones Estructurales (SEM), se refiere a un mecanismo causal a través del cual una variable independiente (el predictor) influye en una variable dependiente (el resultado) a través de una o más variables mediadoras (el proceso) (Hair et al., 2022). Un modelo de mediación completo establece que el efecto del predictor sobre el resultado se transmite total o parcialmente a través del mediador.

La incorporación de mediadores transforma un simple modelo de asociación en un modelo de proceso teórico riguroso. Este enfoque permite a los investigadores especificar no solo si un efecto ocurre, sino también a través de qué pasos intermedios se produce. Este rigor no es solo académico, sino que tiene un valor

estratégico directo para la toma de decisiones empresariales, pues identifica las palancas de gestión intermedias que pueden ser intervenidas para maximizar un resultado deseado (Shmueli et al., 2019).

Aplicaciones:

La mediación es crucial para comprender procesos dinámicos y complejos en gestión, marketing y comportamiento organizacional.

- **Marketing y satisfacción:** La relación entre la calidad del servicio y la lealtad del cliente a menudo está mediada por la satisfacción del cliente. El análisis de mediación permite confirmar que invertir en calidad es más efectivo si primero se maximiza la satisfacción como paso intermedio clave.
- **Comportamiento organizacional y desempeño:** El impacto del liderazgo transformacional sobre el desempeño organizacional puede estar mediado por el compromiso organizacional o la innovación percibida por los empleados. Comprender este sendero permite a los gerentes enfocarse en construir el compromiso como un paso hacia la mejora del desempeño (Kim et al., 2023).
- **Innovación y ventaja competitiva:** La mediación ayuda a entender cómo la cultura de aprendizaje de una empresa impulsa el desempeño financiero a través de la capacidad de innovación (Hair

et al., 2022). Identificar la capacidad de innovación como el mecanismo central permite asignar recursos de forma más eficiente.

En esencia, al revelar los mecanismos subyacentes, el análisis de mediación permite a las organizaciones diseñar intervenciones específicas, maximizando el rendimiento de los recursos invertidos al actuar sobre la variable mediadora más influyente.


7.2 Fundamentos y análisis de mediación en modelos SEM

El análisis de mediación constituye un pilar conceptual y metodológico en la investigación de las ciencias empresariales, al permitir elucidar los mecanismos subyacentes a las relaciones causales observadas entre variables. Su estudio trasciende la mera identificación de asociaciones directas, profundizando en el "cómo" y el "por qué" de los fenómenos (Baron & Kenny, 1986).


Figura 11

Modelo Conceptual


a) **Relación DIRECTA**
(Positiva/Negativa)



b) **Efecto Mediador**
(Mediating Effect)



c) **Efecto Moderador**
(Moderation Effect)



Fuente: Saravia (2024) Universidad del Pacifico PIE

Conexión práctica

🔗 La Mediación como estrategia de negocio

A menudo, los estudiantes piensan que la mediación es solo un cálculo estadístico extra. Sin embargo, en el mundo gerencial, descubrir un mediador significa descubrir la "receta secreta" del éxito.

En el **Caso de Estudio 1 (Capítulo IV)**, analizamos cómo la integración con proveedores *no* genera dinero directamente. Para que sea rentable, debe pasar a través de una "Estrategia SCM interna". Si quiere entender cómo interpretar una Mediación Total y

explicarle a un gerente que "A no causa B, a menos que pase por C", revise el análisis de la Sección 9.1.

7.3 Mediación bajo el enfoque de ecuaciones estructurales

En el marco de los Modelos de Ecuaciones Estructurales (SEM), la mediación se define como un proceso en el cual el efecto de una variable independiente (predictor, X) sobre una variable dependiente (resultado, Y) se transmite, total o parcialmente, a través de una tercera variable, denominada mediador (M) (Preacher y Hayes, 2008). Es decir, el mediador actúa como un mecanismo interviniente que explica la conexión entre el predictor y el resultado. Este enfoque es crucial para la construcción y prueba de teorías en la investigación empírica como se aprecia en la figura 11.

Un modelo de mediación se descompone en varios efectos fundamentales:

- **Efecto directo (Path c')**: La influencia de X sobre Y que no pasa a través del mediador.
- **Efecto indirecto (Path a×b)**: La influencia de X sobre Y que se transmite a través de M (donde X→M es el *path* a, y M→Y es el *path* b).
- **Efecto total (Path c)**: La suma del efecto directo y el efecto indirecto ($c=c'+(a\times b)$).

Tipos de Mediación

La complejidad de las relaciones inter-variables permite la configuración de diversos tipos de mediación:

- **Mediación simple:** Involucra un único predictor (X), un único mediador (M) y un único resultado (Y). Es la estructura básica para comprender el proceso.
- **Mediación múltiple:** Caracterizada por la presencia de dos o más mediadores (M_1, M_2, \dots) que actúan en paralelo para transmitir el efecto de X a Y . Los efectos indirectos se calculan para cada mediador de forma independiente.
- **Mediación serial (o en cadena):** Los mediadores actúan en secuencia, donde el predictor influye en un primer mediador (M_1), este a su vez influye en un segundo mediador (M_2), y así sucesivamente, hasta afectar al resultado ($X \rightarrow M_1 \rightarrow M_2 \rightarrow Y$).
- **Mediación condicionada (o moderada):** El efecto de mediación (el efecto indirecto) varía en función de una tercera variable, denominada moderador. El moderador influye en la fuerza o dirección de las relaciones entre X y M , o entre M y Y .

7.4 Fundamentos y criterios para la detección de mediación

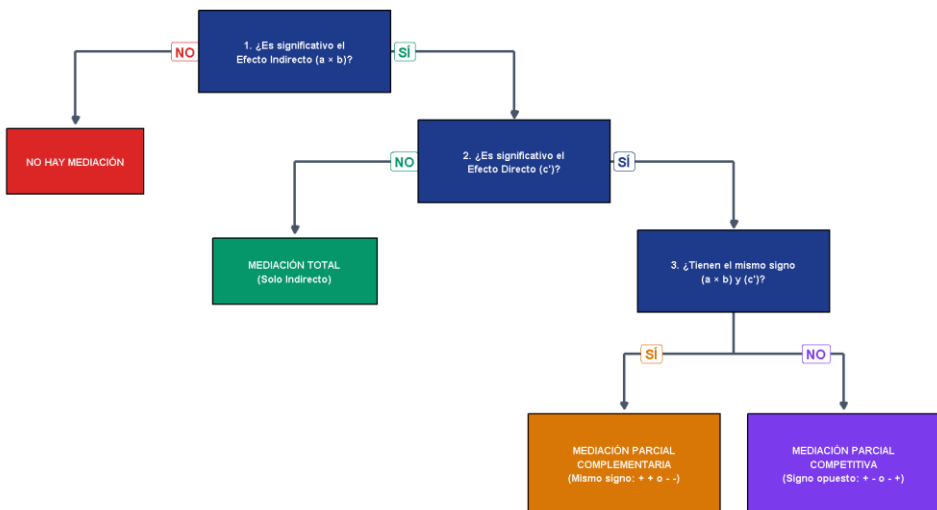
La detección y clasificación de la mediación se fundamenta en la significancia estadística de los efectos directos e indirectos, y en su relación con el efecto total (Hair et al., 2022).

Tradicionalmente, el enfoque de Baron y Kenny (1986) implicaba una serie de pasos secuenciales. Sin embargo, los métodos basados en *bootstrapping* y el análisis de los Intervalos de Confianza (IC) del efecto indirecto total (Preacher y Hayes, 2008) son ahora el estándar en SEM, particularmente en PLS-SEM, ya que no asumen distribuciones normales.

En la figura siguiente en el diagrama de flujo se ilustra un proceso de decisión para clasificar los tipos de mediación, basándose en la significancia de los senderos individuales (p_1 , p_2 , p_3) y el producto de los efectos.

Figura 12

Diagrama de Flujo



Criterios de Clasificación (Adaptado Hair et al., 2022)

1. **Evaluación inicial de los efectos:** Se analiza la significancia de los senderos individuales:
 - **$p1 \times p2$ (Efecto Indirecto):** Representa la ruta de $X \rightarrow M \rightarrow Y$.
 - **$p3$ (Efecto Directo c'):** Representa la ruta de $X \rightarrow Y$ una vez que M está en el modelo.
2. **Mediación total (o solo efecto indirecto):**
 - Si el efecto indirecto ($p1 \times p2$) es significativo, y el efecto directo ($p3$) no es significativo, se infiere que la variable mediadora absorbe completamente el efecto del predictor sobre el resultado. Toda la influencia de X en Y se canaliza a través de M .
3. **Mediación parcial:** Se distingue en dos subtipos según la naturaleza de los efectos:
 - **Mediación complementaria:** Ocurre si el efecto indirecto ($p1 \times p2$) es significativo, y el efecto directo ($p3$) también es significativo, y ambos efectos van en la misma dirección (es decir, tienen el mismo signo, típicamente ambos positivos). El mediador explica una parte significativa del efecto total, pero el predictor aún conserva una influencia directa sobre el resultado.
 - **Mediación competitiva:** Se presenta cuando el efecto indirecto ($p1 \times p2$) es significativo, el efecto directo ($p3$) también es significativo, pero ambos efectos van en

direcciones opuestas (es decir, tienen signos contrarios, por ejemplo, el indirecto es positivo y el directo es negativo, o viceversa). Esto sugiere que el mediador suprime o antagoniza una parte del efecto directo.





4. Solo efecto directo (o no mediación):

- Si el efecto indirecto ($p1 \times p2$) no es significativo, pero el efecto directo ($p3$) es significativo, no hay evidencia de mediación. El predictor influye directamente en el resultado sin pasar por el mediador propuesto.

5. No efecto / No mediación:

- Si ni el efecto indirecto ($p1 \times p2$) ni el efecto directo ($p3$) son significativos, no hay evidencia de relación significativa entre el predictor y el resultado, ni directa ni a través del mediador.

Casos de mediación:



Fuente: (Sarstedt et al., 2020)

- La Figura (a) presenta un ejemplo de un modelo de mediación simple, en el que la variable M1 actúa como mediadora teórica en la relación entre Y1 y Y2. Por su parte, la moderación se refiere a un diseño de investigación en el que una tercera variable influye directamente en la intensidad o incluso en la dirección de la relación entre dos constructos principales.

- Figura (b), donde M2 afecta la fuerza del vínculo entre Y1 y Y2. Ambas perspectivas pueden combinarse: existen situaciones en las que un moderador impacta uno o más efectos directos que forman parte de un proceso mediador, fenómeno conocido como modelo de proceso condicional o mediación moderada.
- Las Figuras (c) y (d) ilustran ejemplos de estos modelos de mayor complejidad, los cuales también pueden extenderse para incorporar múltiples mediadores y moderadores, adaptándose así a estructuras teóricas y aplicaciones analíticas más avanzadas.

Interpretación en términos empresariales

La identificación precisa del tipo de mediación tiene profundas implicaciones estratégicas. En un contexto empresarial, la mediación permite:

- **Identificar palancas de intervención:** Una mediación total, por ejemplo, indica que, para influir en el resultado, la intervención debe dirigirse primordialmente al mediador. Si la satisfacción del empleado media completamente la relación entre el liderazgo participativo y la productividad, la empresa debe enfocarse en programas de satisfacción.


- **Optimizar recursos:** Comprender la mediación permite una asignación más eficiente de recursos, al evitar invertir en factores con efectos directos débiles o inexistentes si existen mediadores más efectivos.
- **Desarrollar estrategias sofisticadas:** Una mediación complementaria sugiere que, además de la acción sobre el mediador, el predictor directo sigue siendo relevante. Una mediación competitiva puede alertar sobre efectos paradójicos, donde la intervención en el mediador podría mitigar un efecto directo positivo o viceversa.

El análisis de mediación no solo enriquece la comprensión teórica, sino que proporciona una hoja de ruta más clara y granular para la gestión estratégica, al explicar los mecanismos causales que impulsan el éxito organizacional.

Aplicación:

Figura 13

*Modelo de reputación corporativa con rutas de mediación resaltadas
(líneas de puntos)*



Identificamos dos rutas de mediación principales a través de la Satisfacción (CUSA): (COMP → CUSA → CUSL) y (LIKE → CUSA → CUSL).

Interpretación del Árbol de Decisión:

La Figura anterior presenta el diagrama de flujo para determinar el tipo de mediación, basado en el árbol de decisión actualizado de Zhao, Lynch y Chen (2010) y Hair et al. (2022). Este proceso lógico guía al investigador paso a paso:

1. **Paso 1:** ¿Existe el efecto indirecto ($a * b$)? Lo primero es verificar si es significativo. Si no lo es, no hay mediación.
2. **Paso 2:** ¿Existe el efecto directo (c')? Si hubo mediación, ahora preguntamos si el camino directo sigue siendo significativo.
 - **NO:** El mediador "absorbió" toda la influencia. Es una Mediación Total.
 - **SÍ:** Hay múltiples causas. Es una Mediación Parcial.
3. **Paso 3:** ¿Qué tipo de parcial? Si ambos efectos son significativos, miramos sus signos. Si apuntan al mismo lado (ambos positivos), es Complementaria. Si se oponen, es Competitiva.

1. Modelo conceptual y datos

Asumamos un modelo teórico que explora cómo la Competencia (X) impacta la lealtad (Y), mediada por la satisfacción (M).

Tabla 27

Constructo y modelo

Constructo	Tipo	Definición en el Modelo Estructural
X (Competencia)	Predictor	Variable independiente (x).
M (Satisfacción)	Mediador	Variable endógena y predictora.
Y (Lealtad)	Resultado	Variable dependiente (Y endógena).

Hipótesis de Mediación: El efecto positivo de la Competencia (X) sobre la Lealtad (Y) está mediado por la Satisfacción (M).

El modelo *path* queda estructurado con tres senderos clave:

- **p1 (a):** Competencia (X) → Satisfacción (M)
- **p2 (b):** Satisfacción (M) → Lealtad (Y)
- **p3 (c'):** Competencia (X) → Lealtad (Y) (Efecto directo)

2. Resultados del análisis de mediación (Bootstrapping)

Tras ejecutar el algoritmo PLS y el procedimiento de *bootstrapping* (con 10,000 submuestras y un nivel de significancia de $\alpha=0.05$), se obtienen los coeficientes de sendero y los efectos de mediación (indirectos):

7.5 Presentación e interpretación de resultados

Presentar los resultados de un análisis de mediación en un artículo científico requiere claridad, precisión y el cumplimiento de estándares metodológicos.

7.5.1 Estructura de reporte de coeficientes

El reporte formal debe incluir una tabla consolidada con los caminos individuales (a, b, c') y sus estadísticas de bootstrapping.

Tabla 28

Coefficientes de sendero y significancia (Modelo de Mediación)

Ruta	Coefficiente β	Valor t	p-value	Decisión
X→M (a)	0,650	12.35	<0.001	Significativo
M→Y (b)	0,380	4.92	<0.001	Significativo
X→Y (c') Directo	0,110	1.78	0,075	No Significativo

7.5.2 Reporte de efectos indirectos

La evaluación central de la mediación se basa en la significancia del efecto indirecto ($a \cdot b$). Se debe reportar el intervalo de confianza (IC).

Tabla 29

Análisis de efectos indirectos y totales

Efecto	Coefficiente	IC 95% (Bias-Corrected)	Decisión
Indirecto ($a \cdot b$)	0,247	[0.155; 0.340]	<input checked="" type="checkbox"/> Significativo (No incluye cero)
Total (c)	0,357	[0.250; 0.464]	<input checked="" type="checkbox"/> Significativo

7.5.3 Redacción

Ejemplo de Mediación Total:

El análisis confirmó la hipótesis de mediación. El efecto indirecto de la Competencia sobre la Lealtad, mediado por la Satisfacción, fue positivo y estadísticamente significativo

(beta=0.247; IC 95% [0.155, 0.340]). En contraste, el efecto directo resultó no significativo (beta=0.110; $p=0.075$).

Estos hallazgos validan una mediación total, indicando que la influencia de la percepción de competencia de la empresa en la lealtad del cliente se canaliza completamente a través de la satisfacción.

7.5.4 Reporte de calidad predictiva

Además de la mediación, se debe confirmar la calidad del modelo siguiendo los estándares modernos (Shmueli et al., 2019):

- **Varianza explicada (R^2):** "El modelo explica el 51.2% de la varianza en la Lealtad ($R^2 = 0.512$)."
- **Poder predictivo (PLSpredict):** "El análisis PLSpredict mostró que el modelo PLS tiene menor error (RMSE) que el modelo lineal en la mayoría de los indicadores, confirmando un poder predictivo medio."

7.6 Aclaraciones metodológicas

Tabla 30

Respuestas a dudas comunes de revisores

Solicitud del Revisor	Respuesta Metodológica Sugerida
¿Cómo aseguraron la significancia del efecto indirecto?	La significancia se determinó mediante bootstrapping (10,000 submuestras, Bias-Corrected Confidence Intervals), siguiendo a Preacher y Hayes (2008), ya que este método no asume normalidad en la distribución del producto de coeficientes.
Aclare la distinción entre mediación total y parcial.	La clasificación se basó en el árbol de decisión de Zhao et al. (2010). Se determinó mediación total porque el efecto indirecto fue significativo, mientras que el efecto directo (c') no lo fue.

7.7 Referencias científicas sobre mediación

Enfoque teórico

1. Lin, S.-K. & Chung, H.-C. (2023). The relationship between entrepreneurial orientation and firm performance from the perspective of MASEM: The mediation effect of market orientation and the moderated mediation effect of environmental dynamism. *SAGE Open*, 13(4). <https://doi.org/10.1177/21582440231218804>
 - Fundamenta teóricamente los efectos mediadores y moderadores en modelos SEM en el contexto de economía empresarial, proponiendo MASEM como integración de meta-análisis y SEM.
2. Uslu, A., Alagöz, S. M., & Gök, T. (2021). The multiple mediation roles of trust and satisfaction in the effect of corporate social responsibility perceptions on behavioral intention. *Business: Theory and Practice*, 22(1), 47–58. <https://doi.org/10.3846/bmee.2021.13362>
 - Analiza la mediación múltiple mediante SEM en intenciones conductuales empresariales, desarrollando constructos

mediadores clave.

Enfoque metodológico

3. Sarstedt, M., Hair, J. F., Nitzl, C., Ringle, C. M., & Howard, M. C. (2020). Beyond a tandem analysis of SEM and PROCESS: Use of PLS-SEM for mediation analyses! *International Journal of Market Research*, 62(3), 288-302.
<https://doi.org/10.1177/1470785320915686>
 - Detalla ventajas y desafíos de distintos enfoques de mediación en SEM, especialmente PLS-SEM, para modelar efectos indirectos complejos.
4. Guenther, P., Henseler, J., & Schuberth, F. (2023). Improving PLS-SEM use for business marketing research: An assessment and practical guideline. *Industrial Marketing Management*, 113, 209-231. <https://doi.org/10.1016/j.indmarman.2023.03.007>
 - Ofrece recomendaciones metodológicas prácticas y revisión exhaustiva sobre la implementación de PLS-SEM en mediación empresarial.
5. Legate, A. E., Ferguson, M., & Ringle, C. M. (2024). PLS-SEM: A method demonstration in the R statistical landscape. *Human Resource Development Quarterly*, 35(2), 145-158.
<https://doi.org/10.1002/hrdq.21517>
 - Expone la aplicación y ventajas del enfoque PLS-SEM en el software R, relevante para estudios de mediación en negocios.

Enfoque aplicado

6. Rodrigues, J., Silva, M., & Magalhães, R. (2021). Mediation role of business value and strategy in firm performance: Evidence from SaaS EA adoption. *Journal of Business Research*, 134, 132–142.
<https://doi.org/10.1016/j.jbusres.2021.05.058>

- Estudio aplicado usando SEM para evaluar cómo el valor de negocio y la estrategia median el efecto de las capacidades en el desempeño empresarial.
7. Changalima, I. A., Ngirwa, J. S., & Ismail, I. J. (2024). Mediating effect of purchasing efficiency on the relationship between purchasing analytical skills and restaurant performance. *Journal of Management and Business Education*, 7(1), 70-81. <https://doi.org/10.1108/jmb-11-2022-0058>
 - Investigación empírica donde la mediación es evaluada mediante SEM para explicar el vínculo entre habilidades de compras y resultados en restaurantes.
 8. Suder, M., & Nowacka, A. (2025). Mediating or moderating? Innovative approach to the role of flexibility in the relationship between entrepreneurial orientation and firm growth in emerging markets. *Journal of Innovation & Knowledge*, 10(1), 45-61. <https://hdl.handle.net/10419/327560>
 - Evalúa el papel mediador/moderador de la flexibilidad empresarial usando SEM en mercados emergentes.
 9. Uslu, A. (2021). The multiple mediation roles of trust and satisfaction in the effect of corporate social responsibility perceptions on behavioral intention. *Business: Theory and Practice*, 22(1), 47–58. <https://doi.org/10.3846/bmee.2021.13362>
 - Caso práctico de aplicación de mediaciones múltiples para analizar impactos en intenciones en el contexto empresarial.
 10. Ballen, C. J., et al. (2021). Mediation analysis in discipline-based education research using structural equation modeling. *Journal of Microbiology & Biology Education*, 22(2), 1-6. <https://doi.org/10.1128/jmbe.00108-21>

- Aplica análisis de mediación vía SEM para explicar resultados en investigaciones educativas de negocios.

ANÁLISIS DE MODERACIÓN EN SEM

La investigación avanzada en ciencias empresariales exige ir más allá de la mera constatación de efectos directos entre variables. Comprender la contingencia de las relaciones causales es decir, cuándo y para quién un efecto es más o menos fuerte es crucial para desarrollar teorías robustas y estrategias gerenciales efectivas (Hair et al., 2022). Aquí es donde el análisis de moderación se establece como una herramienta indispensable dentro del Modelado de Ecuaciones Estructurales (SEM).

7.8 Definición y tipología de la moderación

La moderación describe una situación en la que la relación entre dos variables, un predictor (X) y una variable dependiente (Y), cambia en fuerza o dirección en función de los niveles de una tercera variable, el moderador (Z) (Baron & Kenny, 1986). A diferencia de la mediación (que explica el *cómo*), la moderación explica el *cuándo* o el *para quién* de una relación causal (Hayes, 2018). Como se aprecia en la siguiente figura:


Figura 14

Modelo: Tipo de relaciones entre variables


a) **Relación DIRECTA**
(Positiva/Negativa)



b) **Efecto Mediador**
(Mediating Effect)



c) **Efecto Moderador**
(Moderation Effect)



Fuente: Saravia (2024) Universidad del Pacifico PIE

Tipos de variables moderadoras

La conceptualización del moderador es vital en SEM, particularmente en el enfoque de Mínimos Cuadrados Parciales (PLS-SEM):

- **Moderador observado (o manifiesto):** Es una variable directamente medida (un indicador o un *ítem*). Puede ser categórica (ej., género, tipo de industria) o continua (ej., edad, experiencia). Cuando es categórica, el análisis Multi-Grupo (*Multi-Group Analysis*, MGA) se convierte en la técnica estándar.

- **Moderador latente (o constructo):** Es una variable no observable medida por múltiples indicadores. En SEM, la variable moderadora (Z) es típicamente un constructo latente que interactúa con el predictor (X), también latente, para influir en el resultado (Y) (Henseler & Fassott, 2010).

7.9 Clasificación de la moderación

La moderación se clasifica según la complejidad del modelo y el número de variables involucradas:

- **Moderación simple (o de dos vías):** El efecto más básico, donde una sola variable moderadora (Z) afecta la relación entre un único predictor (X) y el resultado (Y).
- **Moderación múltiple:** Se refiere a un modelo con múltiples variables moderadoras. Esto puede implicar que dos o más moderadores afecten la misma relación ($X \rightarrow Y$), o que diferentes moderadores afecten distintas relaciones dentro del modelo estructural.
- **Moderación condicional (o de tres vías):** Una forma avanzada donde la relación causal entre X y Y está moderada por la interacción de **dos** variables moderadoras (Z1 y Z2). Por ejemplo, el impacto de la Cultura organizacional sobre la Innovación puede

ser más fuerte solo cuando la antigüedad del empleado es baja y la estructura es descentralizada.

7.10 Fundamentos y motivación causal

La incorporación de moderadores no es un ejercicio estadístico; es una exigencia teórica. La motivación para incluir una variable moderadora deriva de la necesidad de establecer los límites de la generalización de una teoría.

Causalidad contingente

En ciencias empresariales, las leyes causales rarely son universales. La eficacia de una estrategia de Liderazgo Transformacional (X) sobre el Desempeño del Equipo (Y) probablemente depende de la **incertidumbre ambiental** (Z) (Wold, 1985). Si la incertidumbre es alta, la relación podría ser muy fuerte (el liderazgo es vital); si es baja, la relación podría ser débil (el liderazgo es menos crítico).

La moderación permite refinar las teorías existentes, transformando proposiciones determinísticas (A siempre causa B) en proposiciones contingentes (A causa B *bajo la condición C*). Esto aumenta la **validez externa** y la **precisión predictiva** de los modelos (Sarstedt et al., 2016).

Valor estratégico y aplicabilidad.

Para la toma de decisiones gerenciales, la moderación tiene un valor incalculable:

- **Segmentación estratégica:** Permite identificar segmentos o contextos (ej., empresas pequeñas vs. grandes, economías estables vs. volátiles) donde una intervención o estrategia particular será más efectiva.
- **Optimización de recursos:** Una organización puede evitar invertir en un programa si el análisis revela que su efecto es nulo o incluso negativo en un contexto específico (nivel bajo del moderador). Por ejemplo, la inversión en **tecnología de e-commerce** (X) puede impactar la **rentabilidad** (Y) solo si la **competencia de precios** (Z) es moderada (Hair et al., 2022).

7.11 Metodología para modelar la moderación en SEM

El modelado de la moderación en SEM, especialmente cuando se trabaja con constructos latentes, requiere técnicas que aborden la complejidad de la interacción entre variables no observables.

Enfoque de indicadores producto (Product Indicator Approach)

Este es el método más tradicional y directo en SEM basado en covarianza (CB-SEM), y ha sido adaptado para PLS-SEM.

- **Mecánica:** Se crea una nueva variable de interacción multiplicando los indicadores del predictor (X) por los indicadores del moderador (Z). Este conjunto de productos actúa como un constructo formativo de segundo orden que representa el término de interacción ($X \times Z$) (Chin et al., 2003).
- **Riesgos:** La principal limitación es que el método genera inevitablemente una **multicolinealidad** alta entre los constructos principales (X , Z) y el término de interacción ($X \times Z$). Esto puede inflar los errores estándar y reducir la significancia estadística.

Enfoque two-stage (Método de dos etapas)

Una alternativa, particularmente útil en PLS-SEM, es el método de dos etapas:

- **Etapa 1:** Estimar las puntuaciones de las variables latentes (constructos X y Z) del modelo.
- **Etapa 2:** Usar las puntuaciones latentes estimadas como variables observadas y crear el término de interacción ($X \times Z$) para una regresión posterior.
- **Ventaja:** Reduce la complejidad del modelo en una sola etapa, pero el *software* moderno de PLS-SEM (ej., SmartPLS 4) ha integrado algoritmos más sofisticados para el manejo de interacciones latentes

que hacen este enfoque menos necesario para constructos Reflexivos.

Uso de algoritmos de interacciones latentes (Latent Variable Interaction)

Algoritmos avanzados (ej., el método **Orthogonalizing Product Indicators** - OPA) abordan el problema de la colinealidad. Estos métodos generan el término de interacción sin el riesgo de colinealidad inherente al enfoque de indicadores producto (Sarstedt et al., 2020). Este es el enfoque preferido cuando se trabaja con variables latentes en PLS-SEM.

Análisis multi-grupo (MGA) como alternativa

Si el moderador es **categorico** (ej., género, región), la técnica más potente y directa no es el término de interacción, sino el **Análisis Multi-Grupo (MGA)**.

- **Mecánica:** El modelo estructural se estima por separado para cada grupo definido por el moderador. Posteriormente, se utiliza una prueba no paramétrica (como la prueba MGA de Henseler) para determinar si los coeficientes de sendero son significativamente diferentes entre los grupos (Henseler et al., 2009).

- **Ventaja:** Evita completamente los problemas de colinealidad asociados a los términos de interacción y proporciona un contraste directo en la fuerza de la relación.

7.12 Supuestos, riesgos y medidas preventivas

El éxito de un análisis de moderación depende de la comprensión de sus desafíos inherentes.

Riesgos metodológicos

- **Multicolinealidad (VIF):** Es el riesgo más grave. La creación del término de interacción ($X \times Z$) aumenta drásticamente la correlación con sus componentes individuales (X y Z). La detección de un Factor de Inflación de Varianza (VIF por encima de 5) en los constructos predictores (incluyendo el término de interacción) sugiere un problema crítico (Hair et al., 2022).
- **Baja potencia estadística:** Detectar efectos de interacción suele requerir muestras más grandes que detectar efectos directos, especialmente si el efecto de interacción es pequeño. La baja potencia puede llevar a un error de Tipo II (no detectar una interacción que realmente existe) (Sarstedt et al., 2020).
- **Centrado de variables (*Mean Centering*):** Aunque centrar las variables X y Z antes de crear el término de interacción no

resuelve el problema de la colinealidad per se, sí facilita la interpretación de los coeficientes principales (X y Z) al asegurar que representen el efecto cuando el moderador está en su valor medio (Hair et al., 2022).

Conexión práctica

🔗 ¿Y si la relación no es una línea recta?

La mayoría de los modelos asumen que "más es mejor" (relación lineal positiva). Pero, ¿qué pasa cuando tener *demasiado* de algo se vuelve negativo?

En el Caso de Estudio 3 (Capítulo IV) sobre riesgo crediticio, se descubrió una paradoja: los clientes con *mayor* capacidad de pago eran *menos* puntuales. Este fenómeno no lineal requiere un análisis cuidadoso. Si su investigación involucra comportamientos financieros o humanos complejos, le recomendamos estudiar el enfoque semiparamétrico detallado en la Sección 9.3.

Medidas preventivas y evaluación

1. **Justificación teórica rigurosa:** Nunca incluya un moderador sin una base teórica sólida. La especificación debe estar impulsada por la literatura que sugiera la contingencia de la relación.

2. **Uso de métodos avanzados:** Preferir los algoritmos de interacción latente que gestionan el problema de la colinealidad, o bien el MGA si el moderador es categórico (Sarstedt et al., 2020).
3. **Evaluación de la significación:** Una vez estimado el modelo, la interpretación requiere graficar la interacción (**análisis *simple slope***) para visualizar cómo cambia la relación $X \rightarrow Y$ en niveles bajos, medios y altos del moderador (Z) (Chin et al., 2003).

El análisis de moderación es fundamental para avanzar hacia modelos causales más precisos y representativos de la complejidad del entorno empresarial. Su aplicación rigurosa asegura que las conclusiones no solo sean válidas, sino estratégicamente aplicables para diferentes contextos organizacionales.

Conexión práctica

Cuando los Datos contradicen la Intuición

El objetivo del SEM es someter nuestras creencias a la prueba de los datos. A veces, las variables que creemos más importantes resultan no ser significativas ($p > 0.05$).

Un ejemplo claro de esto ocurre en el sector salud. En el Caso de Estudio 2 (Capítulo VIII), la intuición sugería que la ubicación de la tienda ("Plaza") era vital. Sin embargo, el modelo estructural reveló que esta ruta no era significativa, mientras que la

"Promoción" era el predictor dominante. Para aprender a interpretar y reportar hipótesis rechazadas con rigor, véase la Sección 8.2.

7.13 Preparación de datos para el análisis de moderación en modelos SEM

El rigor metodológico en el análisis de moderación comienza con una preparación de datos exhaustiva, la cual es crucial para garantizar la validez de los resultados, especialmente cuando se introducen términos de interacción. Esta sección detalla los procedimientos esenciales para preparar los datos para la modelación de moderación en el contexto de los Modelos de Ecuaciones Estructurales (SEM).

1. Evaluación de la distribución y normalidad

Aunque el enfoque de Mínimos Cuadrados Parciales (PLS-SEM) no asume la normalidad multivariante de los datos, la evaluación de la distribución sigue siendo importante, especialmente para la interpretación de las pruebas de significancia.

- **Normalidad univariante y multivariante:** Se recomienda inspeccionar la **asimetría** (*skewness*) y la **curtosis** (*kurtosis*) de los indicadores. En general, valores absolutos de asimetría mayores a |2| y de curtosis mayores a |7| sugieren desviaciones significativas.

- **Decisión práctica:** Si los datos muestran una desviación severa, la elección de PLS-SEM se reafirma, ya que utiliza procedimientos de remuestreo (como el *bootstrapping*) que no dependen de los supuestos paramétricos.

2. Centrado y estandarización de variables latentes

El **centrado de variables** es una práctica fundamental al construir términos de interacción latente ($X \times Z$).

- **Centrado (*Mean Centering*):** Consiste en restar la media de la variable a cada una de sus observaciones. Esto se aplica a las variables predictoras (tanto X como Z) antes de crear su término de interacción ($X \times Z$).
 - **Propósito:** El centrado no elimina la multicolinealidad, pero es esencial para una **interpretación significativa de los coeficientes principales**. Al centrar, el coeficiente β del predictor (X) representa el efecto de X sobre Y cuando el moderador (Z) se encuentra en su valor medio (cero).
- **Estandarización (*Z-scores*):** Transformar las variables a puntuaciones Z (media = 0, desviación estándar = 1) permite comparar directamente la fuerza de los efectos. Esta práctica es opcional, pero ayuda a la interpretación de los coeficientes de sendero y los gráficos de interacción.

3. Diagnóstico de Multicolinealidad (VIF)

La introducción de un término de interacción ($X \times Z$) inherentemente aumenta la colinealidad con sus componentes individuales (X y Z). Por ello, la evaluación del **Factor de Inflación de Varianza (VIF)** es obligatoria en el modelo estructural.

- **Criterio de Evaluación:** El VIF debe calcularse para el conjunto de predictores de la variable endógena, incluyendo el término de interacción. El umbral crítico recomendado es $VIF \leq 5$; sin embargo, muchos investigadores de SEM prefieren un criterio más estricto de $VIF \leq 3$ para garantizar la ausencia de sesgo en los errores estándar.
- **Estrategias de mitigación:**
 1. **Centrado (Prevención Parcial):** Si bien no elimina la colinealidad entre los predictores y el término de interacción, el centrado a menudo reduce la colinealidad entre los indicadores del término de interacción en los enfoques más complejos.
 2. **Uso de métodos de interacción latente:** Se recomienda utilizar los algoritmos de interacción latente de PLS-SEM que están diseñados para minimizar la colinealidad, como el método de **ortogonalización de indicadores producto (*Orthogonalizing Product Indicators*)**, el cual es superior al enfoque tradicional de indicadores producto cuando se trabaja con constructos latentes.
 3. **Análisis Multi-Grupo (MGA):** Si el moderador es categórico, la MGA es la mejor estrategia, ya que compara

directamente los coeficientes de sendero entre grupos y **evita la necesidad de construir términos de interacción.**

4. Cálculo del tamaño muestral y potencia estadística

Detectar efectos de moderación (interacciones) es considerablemente más exigente en términos de tamaño muestral que detectar efectos directos, ya que la interacción generalmente explica una porción pequeña, pero teóricamente significativa, de la varianza total.

- **Importancia de la potencia:** Un tamaño de muestra insuficiente para detectar una interacción puede resultar en un **error de Tipo II** (no rechazar una hipótesis nula falsa), lo que lleva a la conclusión errónea de que no existe moderación.
- **Métodos de cálculo:**
 1. **Regla general:** Una directriz tradicional, aunque simplista, es que el tamaño de la muestra debe ser al menos **diez veces el número máximo de flechas apuntando a cualquier constructo endógeno**. Para moderación, esta regla debe ser interpretada con precaución.
 2. **Análisis de potencia basado en simulación:** El método más riguroso es el análisis de **Monte Carlo**. Este simula la potencia estadística para detectar efectos específicos (incluyendo interacciones) en función de los tamaños de efecto esperados (f^2), la probabilidad de error Tipo I (α) y el tamaño de la muestra. Se recomienda utilizar herramientas como **G*Power** o simulaciones específicas para PLS-SEM.

3. **Fórmula de f^2 Mínimo:** Para asegurar una potencia adecuada (ej., 80% o más), se debe calcular el tamaño de muestra requerido para detectar el tamaño de efecto f^2 más pequeño que se considere relevante. Para la interacción, un f^2 bajo (0.02) ya puede ser relevante.

Los investigadores deben realizar un análisis de potencia *a priori*, utilizando tamaños de efecto bajos a moderados ($f^2 \approx 0.02$ a 0.15) para estimar el tamaño muestral mínimo, reconociendo que la detección de una interacción pequeña puede requerir muestras de 200 a 400 observaciones o más, dependiendo de la complejidad del modelo.

7.14 **Ejemplo: Moderación por Costes de Cambio**

Para ilustrar el análisis, utilizaremos un modelo donde la Satisfacción del Cliente (CUSA) predice la Lealtad (CUSL), y esta relación es moderada por los Costes de Cambio (SWITCH). La hipótesis es que los clientes satisfechos son leales, pero esta lealtad es aún mayor (o menor) dependiendo de qué tan difícil sea cambiar de proveedor.

Figura 15

Modelo de moderación reputación corporativa




Tabla 31

Indicadores de los costes de cambio

Constructo (Variable Latente)	Indicador (Ítem)	Enunciado del Ítem
Costes de Cambio (SWITCH)	switch_1	Me lleva mucho tiempo cambiar a otra empresa.
	switch_2	Me cuesta demasiado cambiar a otra empresa.
	switch_3	Supone mucho esfuerzo acostumbrarme a una nueva empresa con sus "reglas" y prácticas particulares.
	switch_4	En general, sería un problema cambiar a otra empresa.

Interpretación de Resultados

Al ejecutar el modelo en `semint` utilizando el enfoque de dos etapas (*two_stage*), obtenemos los siguientes coeficientes path:

Tabla 32

Prueba de Hipótesis de Moderación

Relación Hipotetizada	Coficiente (β)	T Stat.	Intervalo de Confianza [2.5%;97.5%]	Veredicto
1. Efecto Principal:				
CUSA -> CUSL	0,467	10.117	[0.371; 0.553]	<input checked="" type="checkbox"/> Significativo
2. Efecto Directo del Moderador:				
SC -> CUSL	0,071	1.242	[-0.035; 0.179]	<input checked="" type="checkbox"/> No Significativo
3. Efecto de Interacción:				
CUSA*SC -> CUSL	-0,071	2.290	[-0.136; -0.009]	<input checked="" type="checkbox"/> Significativo

Interpretación de los Hallazgos:

- Relación Base:** La satisfacción tiene un impacto positivo y fuerte sobre la lealtad (beta = 0.467) en el promedio.
- Rol del Moderador Directo:** Curiosamente, los Costes de Cambio por sí solos no influyen significativamente en la lealtad (beta = 0.071, n.s.). Esto indica que poner barreras de salida no genera lealtad automáticamente.
- El Efecto Moderador (Antagonismo):** El término de interacción es significativo y **negativo** (-0.071). Esto indica un efecto de

"amortiguación". A medida que aumentan los costes de cambio, la relación positiva entre satisfacción y lealtad se debilita.

Análisis de Pendientes Simples (Simple Slope Analysis)

Para comprender la magnitud del efecto, analizamos cómo cambia la predicción en diferentes niveles del moderador (desviaciones estándar, SD):

- **En el Promedio (Media de SC):** La relación entre satisfacción y lealtad se mantiene en su valor base de 0.467.
- **Costes Altos (+1 SD):** Si los costes de cambio aumentan, la pendiente disminuye:

$$0.467 + (-0.071 * 1) = 0.396$$

Interpretación: Cuando el cliente se siente "atrapado" (costes altos), su lealtad depende menos de su satisfacción. La empresa retiene al cliente por barreras, no por felicidad.

- **Costes Bajos (-1 SD):** Si los costes de cambio disminuyen, la pendiente aumenta:


$$0.467 + (-0.071 -1) = 0.538$$

Interpretación: Cuando es fácil irse a la competencia (costes bajos), la satisfacción se vuelve crítica. Un cliente libre solo es leal si está muy satisfecho (0.538).

Figura 16

Análisis de pendientes simples (Simple Slope Plot)

Efecto Moderador de los Costes de Cambio (SC)



Pendientes: SC Bajo (-1SD), SC Medio, SC Alto (+1SD)

Nota: La función `slope_analysis()` de `semr` genera visualmente estas tres líneas. Se observará que la línea de "Low SC" tiene la pendiente más inclinada.

Tamaño del efecto de la moderación (f^2)

Finalmente, en la salida de R (`summary_model$fSquare`), el término de interacción `CUSA*SC` muestra un valor de $f^2 = 0.014$.

Utilizando los criterios ajustados de Kenny (2018) para interacciones:

- $f^2 = 0.005$ (Pequeño)
- $f^2 = 0.010$ (Medio)
- $f^2 = 0.025$ (Grande)

Concluimos que el efecto moderador de los costes de cambio tiene una magnitud Media ($0.014 > 0.010$), lo que justifica su inclusión en el modelo estratégico de la empresa.

7.15 Referencias científicas sobre moderación

1. Sandoval, C. (2024). Análisis de mediación moderada mediante ecuaciones estructurales: Un enfoque para investigaciones en gestión de empresas. *Yulök Revista de Innovación Académica*, 8(1), 31–46.
<https://revistas.utn.ac.cr/index.php/yulok/article/download/645/112/8/2179>
· Explica detalladamente cómo implementar modelos de moderación y mediación en SEM en estudios empresariales, incluyendo el diseño conceptual, la parametrización en software (AMOS, EQS, Mplus, Stata), y casos prácticos de innovación, talento creativo y gestión empresarial.
2. Hayes, A.F. (2018). *Introduction to Mediation, Moderation, and Conditional Process Analysis: A Regression-Based Approach* (2nd Edition). The Guilford Press.
<https://bookdown.org/ccolonescu/RPoE4/mediation-and-moderation-analysis.html>
· Libro de referencia en SEM sobre técnicas para moderación y mediación, ampliamente aplicadas en estudios empresariales, con ejemplos y código aplicable en CB-SEM y PLS-SEM.
3. Moya, J.M. & Lafuente, R. (2023). MODELO DE ECUACIONES ESTRUCTURALES PARA LA MEDIACIÓN Y MODERACIÓN EN EL SECTOR EDUCATIVO Y EMPRESARIAL. Dialnet-Artículo. <https://dialnet.unirioja.es/descarga/articulo/10104295.pdf>
· Presenta ejemplos y fundamentos prácticos para analizar efectos de moderación y mediación en SEM en contextos empresariales y educativos.
4. Hair, J.F., Hult, G.T., Ringle, C.M., & Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*. Sage Publications. <https://www.econbiz.de/Record/a-primer-on-partial-least-squares-structural-equation-modeling-pls-sem-hair-joseph/10011566584>

- Manual avanzado sobre aplicación de análisis de moderación en PLS-SEM para estudios empresariales.
5. Schumacker, R.E. & Lomax, R.G. (2016). Structural Equation Modeling: A Second Course. (PDF - Academia.edu)
[https://www.academia.edu/13420074/Structural equation modelin
g_A second generation multivariate analysis](https://www.academia.edu/13420074/Structural_equation_modeling_A_second_generation_multivariate_analysis)
 · Incluye secciones de moderación en SEM con casos aplicados a ciencias empresariales.
 6. Rebolledo, C., & Sandoval, C. (2023). Métodos CB-SEM vs. PLS-SEM para la investigación en gestión empresarial: comparación de técnicas para efectos moderadores. ScienceDirect.
[https://translate.google.com/translate?u=https%3A%2F%2Fwww.s
ciencedirect.com%2Fscience%2Farticle%2Fpii%2FS0040162521
005254&hl=es&sl=en&tl=es&client=srp](https://translate.google.com/translate?u=https%3A%2F%2Fwww.sciencedirect.com%2Fscience%2Farticle%2Fpii%2FS0040162521005254&hl=es&sl=en&tl=es&client=srp)
 · Artículo comparativo sobre la implementación de moderación en modelos estructurales empresariales usando CB-SEM y PLS-SEM.
 7. Lin, S.-K. & Chung, H.-C. (2023). The relationship between entrepreneurial orientation and firm performance from the perspective of MASEM: The mediation effect of market orientation and the moderated mediation effect of environmental dynamism. SAGE Open, 13(4).
<https://doi.org/10.1177/21582440231218804>
 · Fundamenta teóricamente los efectos de moderación y mediación en modelos SEM en economía empresarial, empleando MASEM como integración de meta-análisis y SEM.
 8. Kock, N. (2016). Moderation analysis in SEM: Techniques and graphical tools for business research.
[https://www.researchgate.net/publication/311539734 Moderation
Analysis in SEM](https://www.researchgate.net/publication/311539734_Moderation_Analysis_in_SEM)
 · Explica técnicas gráficas y analíticas para la moderación en modelos SEM aplicados a la investigación empresarial.

9. Preacher, K. J., Rucker, D. D., & Hayes, A. F. (2007). Addressing Moderated Mediation Hypotheses: Theory, Methods, and Power Analysis in SEM. *Psychological Methods*, 12(1), 50–66.
<https://psycnet.apa.org/record/2007-03565-004>
 - Desarrolla teorías y métodos para probar modelos de mediación moderada y moderación en el contexto SEM.

10. Cepeda, G. & Roldán, J.L. (2004). Aplicando modelos de ecuaciones estructurales en ciencias sociales. *Papeles del psicólogo*, 25(1), 101-113.
<https://www.papelesdelpsicologo.es/pdf/1794.pdf>
 - Incluye fundamentos y ejemplos de moderación en SEM con aplicaciones empresariales en español.

Referencias

- Baron, R. M., & Kenny, D. A. (1986). The moderator-mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, 51(6), 1173-1182. <https://doi.org/10.1037/0022-3514.51.6.1173>
- Chin, W. W., Marcolin, B. L., & Newsted, P. R. (2003). A partial least squares latent variable modeling approach for measuring interaction effects: Results from simulation studies and an actual data analysis. *Information Systems Research*, 14(2), 189-217. <https://doi.org/10.1287/isre.14.2.189.16018>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (4.^a ed.). SAGE Publications.
- Hayes, A. F. (2018). *Introduction to Mediation, Moderation, and Conditional Process Analysis: A Regression-Based Approach* (2.^a ed.). The Guilford Press.
- Henseler, J., & Fassott, G. (2010). Testing moderating effects in PLS path models: An illustration of a customer satisfaction model. *Marketing Letters*, 21(1), 1-11.
- Henseler, J., Ringle, C. M., & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. En N. K.

Malhotra (Ed.), *Advances in International Marketing* (Vol. 20, pp. 277-320). Emerald Group Publishing Limited.

Sarstedt, M., Hair, J. F., Ringle, C. M., Thiele, K. O., & Gudergan, S. P. (2016). Estimation issues with formative measurement: A two-stage solution using PLS-SEM. *Journal of Business Research*, 69(1), 154-160. <https://doi.org/10.1016/j.jbusres.2015.03.042>

Sarstedt, M., Ringle, C. M., & Hair, J. F. (2020). Considering and dealing with endogeneity in PLS-SEM: An applied guide. *European Journal of Marketing*, 54(11), 2739-2761. <https://doi.org/10.1108/EJM-10-2019-0750>

Wold, H. (1985). Systems analysis by partial least squares. En P. Nijkamp, H. Leitner, & N. Wrigley (Eds.), *Measuring the Unmeasurable* (pp. 373-394). Springer-Verlag.

CAPITULO VIII

SOFTWARE ESPECIALIZADO Y CIENCIA ABIERTA EN SEM

La investigación cuantitativa moderna ya no se realiza con lápiz y papel. En disciplinas como las ciencias empresariales, la psicología o la gestión pública, la complejidad matemática de los Modelos de Ecuaciones Estructurales (SEM) hace imprescindible el uso de software avanzado. Un modelo estructural estándar puede requerir la estimación simultánea de docenas de parámetros, el cálculo de matrices de covarianza inversas y la ejecución de miles de submuestras para el *bootstrapping*.

Este capítulo presenta un panorama completo del software utilizado en el análisis de SEM, tanto de pago como de acceso libre, incluyendo AMOS, SmartPLS, Mplus, lavaan y semnr. Se enfatiza la importancia de adoptar principios de ciencia abierta en el proceso investigativo, promoviendo la transparencia, la replicabilidad y la eficiencia analítica mediante lenguajes de programación como R.

Sin embargo, el software no es una simple "caja negra" donde entran datos y salen verdades. La elección del paquete estadístico condiciona la investigación: determina qué tipo de estimador se usará (¿Covarianza o Varianza?), qué tan robustos serán los resultados ante datos imperfectos y cómo se visualizarán los hallazgos.

Se incluyen criterios para seleccionar herramientas según el propósito del estudio, la experiencia del investigador y la complejidad del modelo.

8.1 Elección entre interfaz gráfica y código

Antes de elegir una marca específica, el investigador debe decidir su estilo de trabajo. Existen dos grandes familias de software:

1. Software Basado en Interfaz Gráfica (GUI):

- *La experiencia:* Es como dibujar en una pizarra digital. Usted arrastra rectángulos (variables observadas) y círculos (constructos), los une con flechas y presiona un botón de "Calcular".
- *Ejemplos:* AMOS, SmartPLS.
- *Ventaja:* Curva de aprendizaje muy rápida; ideal para ver la teoría.
- *Desventaja:* Puede volverse tedioso para modelos gigantes o repetitivos.

2. Software Basado en Sintaxis (Código):

- *La experiencia:* Es como escribir una receta. Usted escribe las relaciones en texto (ej. Lealtad \approx Satisfacción + Calidad) y ejecuta el script.

- *Ejemplos:* R (lavaan, semnr), Mplus, EQS.
- *Ventaja:* Control total, replicabilidad absoluta y velocidad en modificaciones.
- *Desventaja:* Requiere aprender un "lenguaje" nuevo.

8.2 Software comercial

Estas herramientas suelen ofrecer soporte técnico, manuales oficiales y estabilidad garantizada. Son comunes en universidades que compran licencias corporativas.

8.2.1 IBM SPSS AMOS: El Estándar Visual para CB-SEM

Es probablemente la puerta de entrada más común al mundo SEM. Se integra con SPSS, lo que facilita la importación de bases de datos.

- **Enfoque:** CB-SEM (Basado en Covarianzas).
- **Ejemplo de Uso:** Un investigador en Recursos Humanos quiere probar si el "Clima Laboral" influye en el "Desempeño". En AMOS, dibuja dos óvalos, conecta una flecha y, si el modelo no ajusta bien (Chi-cuadrado alto), el software sugiere visualmente qué flechas agregar (índices de modificación).

- **Limitación:** No es bueno para PLS-SEM ni para datos que no siguen una curva normal perfecta.

8.2.2 SmartPLS: El Gigante del Enfoque PLS

Es la herramienta líder en marketing y administración estratégica. A diferencia de AMOS, se enfoca en maximizar la predicción (R^2).

- **Enfoque:** PLS-SEM (Basado en Varianza).
- **Ejemplo de Uso:** Un consultor analiza la satisfacción del cliente con una muestra pequeña ($N=80$) y datos asimétricos. SmartPLS le permite dibujar el modelo, ejecutar el algoritmo PLS y, con un solo clic, generar el Mapa de Importancia-Desempeño (IPMA) coloreado.
- **Ventaja Clave:** Su interfaz es moderna y ofrece informes automáticos en Excel y HTML muy detallados.

8.2.3 Mplus: La Potencia Estadística

Es considerado el "Ferrari" de los softwares SEM comerciales. Aunque permite diagramas, su fuerza está en su sintaxis.

- **Enfoque:** Híbrido y avanzado.

- **Ejemplo de Uso:** Un sociólogo estudia la delincuencia juvenil a lo largo de 10 años (datos longitudinales) con variables categóricas (sí/no). Mplus maneja estas complejidades multinivel mejor que casi cualquier otro programa.

8.3 Software de acceso libre

La tendencia mundial hacia la "Ciencia Abierta" ha posicionado a estas herramientas como las favoritas de los investigadores que desean compartir sus métodos sin barreras económicas.

8.3.1 El Ecosistema R: `lavaan` y `semnr`

R es un lenguaje de programación estadística gratuito. Para SEM, tiene dos "motores" principales:

- `lavaan` (Para CB-SEM):

Busca replicar la potencia de Mplus y EQS pero gratis.

- *Ejemplo de Sintaxis:* Para definir que la variable latente "Visual" se mide con tres ítems, simplemente escribes: `Visual =~ x1 + x2 + x3`. Es limpio y directo.

Es una librería moderna diseñada para hablar el idioma del investigador, no del programador.

- *Ejemplo de Uso:* Permite definir modelos complejos (formativos y reflectivos) y obtener validaciones de última generación (como HTMT para validez discriminante) que otros softwares comerciales tardan años en implementar.

8.3.2 Jamovi y JASP: Lo mejor de dos mundos

Son programas gratuitos que se instalan como un software normal (no parecen código de programación). Por detrás usan R, pero el usuario solo ve menús y botones.

- **Ejemplo de Uso:** Un estudiante de tesis necesita hacer un Análisis Factorial Confirmatorio (CFA) rápido. Abre Jamovi, carga su Excel, y arrastra las variables al panel lateral. El programa le da la tabla APA lista para copiar y pegar. Son excelentes para la docencia.

8.4 Escenarios Prácticos de Decisión

Para aterrizar la teoría, analicemos tres casos hipotéticos que ilustran qué software elegir:

Caso A: El investigador de marketing con presupuesto cero

- *Situación:* Está estudiando "Lealtad de Marca" en consumidores. Su muestra es pequeña (100 personas) y sus datos no son normales. No tiene dinero para licencias.
- *Recomendación:* **R con el paquete `semnr`**.
- *Por qué:* Es gratis, maneja perfectamente muestras pequeñas (PLS) y datos no normales. Además, `semnr` es muy fácil de aprender.

Caso B: El consultor corporativo

- *Situación:* Debe presentar un informe de "Clima Organizacional" a la gerencia. Necesita gráficos impactantes y rápidos. La empresa paga la licencia.
- *Recomendación:* **SmartPLS 4**.
- *Por qué:* La capacidad de generar gráficos coloreados (como el IPMA) y reportes ejecutivos automáticos ahorra tiempo y comunica mejor a los gerentes.

Caso C: El investigador en psicometría

- *Situación:* Está validando un test de inteligencia a nivel nacional (N=5000). Necesita probar la "Invarianza" (que el test funcione igual en hombres y mujeres).

- *Recomendación: AMOS (si prefiere visual) o R lavaan.*
- *Por qué:* Necesita el enfoque CB-SEM para evaluar el ajuste global estricto (RMSEA, CFI) y comparar grupos, algo donde PLS no es el estándar tradicional.

La Ventaja de la Ciencia Abierta con R

Mientras que el software comercial facilita el análisis mediante interfaces gráficas, el uso de **R** (a través de paquetes como `semnr` o `lavaan`) ofrece ventajas superiores para la investigación moderna: transparencia total del código, reproducibilidad de los resultados y acceso inmediato a los últimos algoritmos desarrollados por la comunidad científica, sin depender de actualizaciones de licencias costosas.

8.5 Inteligencia Artificial en SEM

El software SEM está dejando de ser una herramienta pasiva para convertirse en un asistente inteligente.

1. Asistentes de Código (Copilot/ChatGPT):

Ya no es necesario memorizar la sintaxis de R de memoria.

- *Ejemplo real:* Un investigador puede escribir en ChatGPT: *"Actúa como un experto en estadística y génrame el código para R usando `semnr` donde la variable 'Confianza' es*

mediadora entre 'Calidad' y 'Lealtad'". La IA escribirá el script base en segundos.

2. Integración con Python (semopy):

Para las empresas que hacen Big Data, Python es el rey. Librerías como semopy permiten integrar un modelo de ecuaciones estructurales dentro de una aplicación web o un sistema de predicción de ventas en tiempo real.

8.6 Referencias sobre software SEM

Para profundizar en el manejo técnico, se recomiendan los siguientes manuales de referencia:

- **Para R (semplr):** Hair, J. F., et al. (2021). *Partial Least Squares Structural Equation Modeling (PLS-SEM) Using R*. Springer. (La guía definitiva para el enfoque de este libro).
- **Para R (lavaan):** Rosseel, Y. (2012). lavaan: An R Package for Structural Equation Modeling. *Journal of Statistical Software*.
- **Para AMOS:** Byrne, B. M. (2016). *Structural Equation Modeling with AMOS*. Routledge. (Excelente para entender la interfaz visual).
- **Para SmartPLS:** Ringle, C. M., Wende, S., & Becker, J.-M. (2022). *SmartPLS 4*. Oststeinbek: SmartPLS.

8.7 Referencias sobre el uso de software SEM

A. AMOS

1. Byrne, B.M. (2022). *Structural Equation Modeling with AMOS: Basic Concepts, Applications, and Programming*. Routledge.
<https://2024.sci-hub.se/6246/ff1297a5a36ecf2c7206266459a8ef34/byrne2016.pdf>
 · Manual académico y aplicado, con ejemplos y casos empresariales.
2. Kiani, M., et al. (2020). Application of AMOS software in determining the relationship between human resource management practices and organizational commitment.
<https://www.scielo.br/j/ram/a/MtCHdpD7SVSZQdrQyTHTxcH/?format=html&lang=en>

Caso de uso en gestión de recursos humanos.

B. LISREL

3. Márquez, P., & Murillo, E. (2022). Aplicación de Modelos de Ecuaciones Estructurales con LISREL en marketing relacional.
<https://f1000research.com/articles/12-1040>
 · Ejemplo en marketing relacional.
4. Ikram, A.A.D.W., et al. (2025). Empleo de modelos de ecuaciones estructurales para analizar factores de políticas públicas en gobiernos locales. *Sustainability* 17(15).
<https://www.mdpi.com/2071-1050/17/15/6855>
 · Uso de LISREL en gestión pública.

C. Mplus

5. Kim, S., & Hwang, S. (2016). Analyzing the Effects of Leadership Styles Using SEM and Mplus Software.
<https://journals.sagepub.com/doi/10.1177/0018720815581931>
https://scholar.google.com/citations?view_op=view_citation&hl=en&user=ExzfgcsAAAAJ&citation_for_view=ExzfgcsAAAAJ:d1gkVwhDpl0C
 - Modelo SEM aplicado a estilos de liderazgo.
6. Maynez Guaderrama, A.I. & López Torres, V.G. (2025). Modelos de ecuaciones estructurales como técnica de análisis en ciencias administrativas.
https://astraeditorialshop.com/wp-content/uploads/2025/04/Modelos-de-ecuaciones-estructurales-como-tecnica_.pdf
 - Capítulo sobre Mplus y ejemplos empresariales.

D. SmartPLS

7. Hair, J.F., Ringle, C.M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*.
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1954735
 - Uso en marketing y gestión empresarial.
8. Vidal-Portilla, E., et al. (2023). Modelamiento mediante ecuaciones estructurales (PLS-SEM) en la investigación en ciencias empresariales.
<https://revistas.pucp.edu.pe/index.php/contabilidadyNegocios/artic/le/view/26930>
 - Ejemplo de PLS-SEM en competitividad empresarial.

E. R/lavaan

9. Rosseel, Y. (2012). lavaan: An R Package for Structural Equation Modeling. *Journal of Statistical Software*, 48(2), 1–36.
<https://www.jstatsoft.org/article/view/v048i02/v48i02.pdf>
· Presenta el uso del paquete lavaan para SEM en R.
10. Mendez, M., & Guzmán, A. (2020). Modelo SEM basado en valores organizacionales y capital humano en empresas ecuatorianas, con R/lavaan.
<https://retos.ups.edu.ec/index.php/retos/article/view/19.2020.01>
· Aplicación práctica con código en lavaan en empresas.

Jamovi

1. **Alamer, A. (2025). Modelado de ecuaciones estructurales (SEM) en la investigación educativa: Tutorial aplicado con Jamovi.**
ScienceDirect - Annals of Educational Research, 2(1).
<https://www.sciencedirect.com/science/article/pii/S2772766125000230>
· Este artículo presenta un tutorial detallado (paso a paso) para el modelado SEM usando el software abierto Jamovi, incluyendo ejemplos prácticos, interpretación de índices de ajuste y comparación con otros programas. Contiene datos simulados y código, útil para quienes desean implementar SEM en Jamovi.
2. **Universidad de Lima (2024). Análisis de Ecuaciones Estructurales - SIA II con Jamovi.**
Repositorio Studocu, documento académico.
<https://www.studocu.com/pe/document/universidad-de-lima/seminario-de-investigacion-i/ss-ecuaciones-estructurales/110492399>
· Presenta un análisis aplicado de modelos estructurales usando Jamovi en el contexto de investigación universitaria (SIA II), con explicación de estimadores, opciones de salida, visualización de resultados y recomendaciones para interpretar los parámetros en SEM.

Referencias

- Bentler, P. M. (2006). *EQS 6 Structural Equation Modeling Software*. Multivariate Software.
- Bezanson, J., Edelman, A., Karpinski, S., & Shah, V. B. (2017). Julia: A fresh approach to numerical computing. *SIAM Review*, 59(1), 65-98. <https://doi.org/10.1137/141000671>
- Byrne, B. M. (2022). *Structural Equation Modeling with AMOS: Basic Concepts, Applications, and Programming* (4.^a ed.). Routledge.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis* (8.^a ed.). Cengage.
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139-152. <https://doi.org/10.2753/MTP1069-6679190202>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2022). Artificial intelligence in structural equation modeling: Opportunities and challenges. *Journal of Business Research*, 143, 230-245. <https://doi.org/10.1016/j.jbusres.2022.01.046>
- Igamberdiev, A. (2020). semopy: Structural Equation Modeling in Python. *Journal of Open Source Software*, 5(56), 2431. <https://doi.org/10.21105/joss.02431>
- Kline, R. B. (2016). *Principles and Practice of Structural Equation Modeling* (4.^a ed.). Guilford Press.
- Muthén, L. K., & Muthén, B. O. (2017). *Mplus User's Guide* (8.^a ed.). Muthén & Muthén.
- Rosseel, Y. (2012). lavaan: An R Package for Structural Equation Modeling. *Journal of Statistical Software*, 48(2), 1-36.

Schumacker, R. E., & Lomax, R. G. (2021). *A Beginner's Guide to Structural Equation Modeling* (5.^a ed.). Routledge.

CAPITULO IX

ARQUITECTURA DE MODELOS

Este capítulo recoge aplicaciones prácticas del SEM en diversos contextos empresariales, desde gestión de la cadena de suministro y riesgo crediticio hasta marketing digital y transformación digital. Cada caso se presenta bajo una estructura estandarizada para facilitar la comparación transversal y la transferencia de conocimientos: contexto organizacional, modelo conceptual, operacionalización de constructos, estimación de parámetros, evaluación del modelo y recomendaciones gerenciales.

El capítulo culmina con una síntesis general y una matriz de aplicabilidad, que permite al lector identificar los modelos más adecuados para problemáticas específicas en su ámbito de investigación o práctica profesional.

De la teoría estadística a la evidencia estratégica

La investigación en ciencias empresariales ha transitado en la última década de un enfoque meramente descriptivo a uno explicativo y predictivo. En este nuevo escenario, la intuición gerencial ya no es suficiente; se requiere evidencia robusta. El valor real del Modelado de Ecuaciones Estructurales (SEM) no reside en la complejidad de sus algoritmos

matemáticos, sino en su capacidad única para operacionalizar la realidad organizacional.

Fenómenos críticos como la *lealtad del cliente*, la *innovación corporativa*, la *cultura organizacional* o el *riesgo percibido* son, por definición, intangibles. No pueden medirse con una regla o un estado financiero; son constructos latentes. SEM actúa como el puente metodológico que permite transformar estos conceptos abstractos en modelos medibles, gestionables y, sobre todo, rentables.

A diferencia de las técnicas de regresión tradicionales que analizan variables de forma aislada, SEM permite evaluar sistemas de causalidad, donde una variable puede ser causa y efecto simultáneamente (mediación), o donde las relaciones cambian según el contexto (moderación). Esto ofrece a la alta dirección una "visión de rayos X" sobre cómo funcionan realmente sus organizaciones.

El objetivo es cerrar la brecha entre la teoría estadística y la práctica profesional. Para ello, hemos deconstruido nueve investigaciones empíricas de alto impacto, presentándolas no solo como artículos académicos, sino como plantillas arquitectónicas que el lector puede replicar y adaptar.

A través de una selección rigurosa, analizaremos cómo investigadores y gerentes han utilizado SEM para resolver problemas complejos en cuatro dimensiones clave:

1. **Gestión de Operaciones:** ¿Cómo la integración de la cadena de suministro impacta el ROI? (Caso 1).
2. **Marketing Estratégico:** Desde el mix tradicional en salud (Caso 2) hasta el comportamiento en redes sociales (Caso 5) y el e-commerce en mercados emergentes (Casos 7 y 8).
3. **Finanzas y Riesgos:** Modelado de comportamientos no lineales en el pago de créditos (Caso 3).
4. **Comportamiento Humano:** Predicción de la motivación (Caso 4) y gestión del talento internacional (Caso 6).

Cada caso se presenta bajo una estructura estandarizada que incluye el Contexto del Problema, la Arquitectura del Modelo, los Hallazgos Estadísticos y, fundamentalmente, las Implicaciones para la Toma de Decisiones.

9.1 **Gestión de la Cadena de Suministro (SCM) e Impacto Financiero**

Referencia Base: Wisner, J. D. (2003). A Structural Equation Model of Supply Chain Management Strategies and Firm Performance. *Journal of Business Logistics*, 24(1), 1–26.

🔗 **Enlace de Acceso:** <https://doi.org/10.1002/j.2158-1592.2003.tb00030.x>

El estudio resuelve una disyuntiva clásica en operaciones: ¿La integración con proveedores y clientes genera rentabilidad real o solo eficiencia operativa? El autor utiliza SEM para probar que la gestión de la cadena de suministro (SCM) es el eslabón mediador necesario entre las relaciones externas y el éxito financiero.

B. Operacionalización de Variables

- **Variables Exógenas (Independientes):**

1. **Estrategia de Gestión de Proveedores (SUPPLY):**

Medida por ítems como "Participación del proveedor en el diseño", "Alianzas estratégicas".

2. **Estrategia de Relación con Clientes (CUST):** Medida por

"Frecuencia de contacto", "Sistemas de respuesta rápida".

- Variable Mediadora (Central):

3. **Estrategia SCM (SCM_STRAT):** Constructo integrador medido por "Nivel de integración de sistemas", "Coordinación de inventarios".

- Variable Endógena (Dependiente):

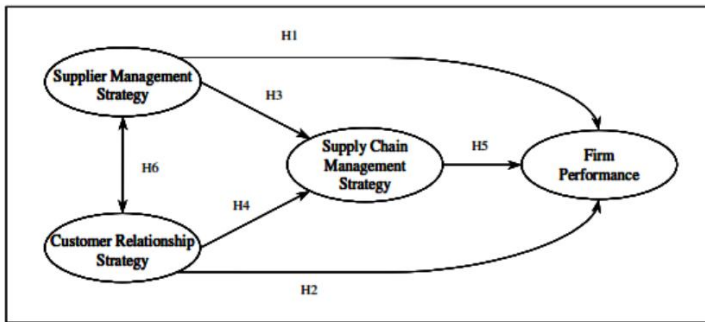
4. **Rendimiento Empresarial (PERF):** Medido por "Cuota de mercado", "ROI", "Crecimiento de ventas".

C. Esquema del Modelo Estructural y Resultados de Hipótesis

El modelo plantea una estructura de mediación total.

- **H_3: Estrategia de Proveedores → Estrategia SCM.**
 - *Resultado: Aceptada.* Una buena gestión de compras es pre-requisito para una SCM integrada.
- **H_4: Estrategia de Clientes → Estrategia SCM.**
 - *Resultado: Aceptada.* La demanda del cliente "jala" la integración de la cadena.
- **H_5: Estrategia SCM → Rendimiento Empresarial.**
 - *Resultado: Aceptada.* Este es el hallazgo clave: las relaciones con proveedores/clientes solo monetizan si pasan por una estrategia SCM cohesiva.
- **H_6: Estrategia de Proveedores → Estrategia de Clientes (Correlación).**
 - *Resultado: Significativa.* Existe una sinergia: las empresas buenas comprando suelen ser buenas vendiendo.

Modelo de ecuación estructural hipotética



D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Replicar este modelo en el sector de **Servicios Digitales** o **SaaS** (Software as a Service), donde la "cadena de suministro" es de datos y no de productos físicos.
¿Se mantiene la mediación de la SCM?

9.2 El Marketing Mix en Productos de Salud (Decisión de Compra)

Referencia Base: Djan, I., & Fitriyanti, R. (2017). The Analysis of Price, Promotion, and Place and Their Effect on Consumer Decision Making. *The Management Journal of Binaniaga*, 2(2), 1-14.

 **Enlace de Acceso:**

<https://media.neliti.com/media/publications/267774-the-analysis-of-price-promotion-and-plac-07a0cdd5.pdf>

A. Contexto y Objetivo

En el mercado de dispositivos médicos personales (ej. tensiómetros Omron), la compra es racional pero influenciable. El estudio busca determinar qué "P" del Marketing Mix (Precio, Promoción, Plaza) pesa más en la decisión final del consumidor.


B. Operacionalización de Variables

- **Variables Exógenas:**
 1. **Precio (X₁):** Competitividad, correspondencia calidad-precio, descuentos.
 2. **Promoción (X₂):** Claridad publicitaria, fuerza de ventas, información técnica.
 3. **Plaza/Distribución (X₃):** Accesibilidad, ubicación de tiendas, inventario disponible.
- Variable Endógena:
 4. Decisión de Compra (Y): Intención de adquirir el producto específico.

C. Esquema del Modelo Estructural y Resultados

Modelo de efectos directos competitivos.

- **H_1: Precio → Decisión de Compra.**
 - *Coeficiente (CR):* 2.399 ($p < 0.05$).
 - *Resultado:* **Aceptada.** El precio justo es determinante.
- **H_2: Promoción → Decisión de Compra.**
 - *Coeficiente (CR):* 3.493 ($p < 0.01$).
 - *Resultado:* **Aceptada.** Es el predictor más fuerte. En salud, la información (promoción) reduce la incertidumbre.
- **H_3: Plaza → Decisión de Compra.**
 - *Coeficiente (CR):* -1.089 ($p > 0.05$).
 - *Resultado:* **Rechazada.** La ubicación física no influye significativamente.



D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Incorporar una variable moderadora como "Nivel de Conocimiento Tecnológico" del usuario

(ancianos vs. jóvenes). ¿La "Promoción" sigue siendo tan importante para los nativos digitales o ellos dependen más de "Reviews Online" (eWOM)?

9.3 Riesgo Crediticio y No-Linealidad (Enfoque Semiparamétrico)

Referencia Base: Junianto, Fernandes, A. A. R., Solimun, & Hamdan. (2021). Structural Equation Modeling Semiparametric in Modeling the Accuracy of Payment Time. *JTAM (Jurnal Teori dan Aplikasi Matematika)*, 5(1), 11-22.

 **Enlace de Acceso:**

<http://journal.ummat.ac.id/index.php/jtam/article/view/23668>

A. Contexto y Objetivo

Desafía la asunción lineal de que "más dinero = mejor pagador". Utiliza un enfoque avanzado (SEM Semiparamétrico con Splines) para detectar comportamientos complejos en deudores hipotecarios.

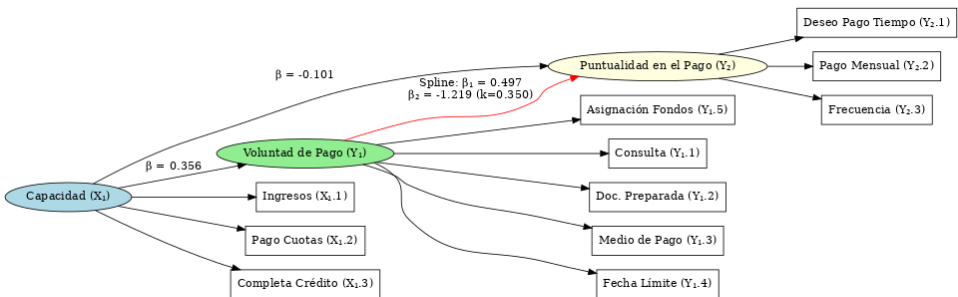
B. Operacionalización de Variables

- **Exógena (X₁): Capacidad de Pago.** (Ingresos, ratio deuda/ingreso).
- **Mediadora (Y₁): Voluntad de Pagar.** (Actitud psicológica, preparación de documentos).
- **Endógena (Y₂): Puntualidad.** (Frecuencia de retrasos).

C. Esquema del Modelo y Resultados Clave

El modelo detectó una relación no lineal con un punto de quiebre (knot) en la Voluntad de Pagar ($K=0.350$).

- **Ruta $X_1 \rightarrow Y_2$ (Capacidad \rightarrow Puntualidad):**
 - *Hallazgo: Coeficiente Negativo ($\beta = -0.101$).*
Paradoja: Clientes con *mayor* capacidad tienden a pagar *menos* puntual (posiblemente por priorizar otras inversiones).
- **Ruta $Y_1 \rightarrow Y_2$ (Voluntad \rightarrow Puntualidad):**
 - *Régimen 1 (Voluntad Baja):* Relación positiva. Mejorar la actitud mejora el pago.
 - *Régimen 2 (Voluntad Alta):* Relación negativa o inversa. Comportamiento impredecible en el extremo superior.



D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Replicar en **Microfinanzas**. ¿Se mantiene la relación negativa entre Capacidad y Puntualidad

en emprendedores de bajos recursos? Es probable que allí la relación sea lineal positiva.

9.4 Psicología Educativa y Motivación Investigativa

Referencia Base: Carranza Esteban, R. F., et al. (2024). Emotional exhaustion, academic self-efficacy, and academic procrastination as predictors of research motivation. *Frontiers in Education*, 8.

🔗 **Enlace de Acceso:** <https://doi.org/10.3389/feduc.2023.1147599>

A. Contexto y Objetivo

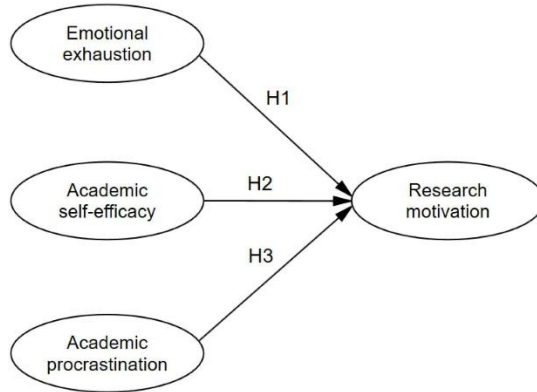
En el contexto universitario post-pandemia, se busca entender qué frena a los estudiantes a investigar. El modelo contrasta factores de habilidad (autoeficacia) contra factores emocionales (agotamiento).

B. Operacionalización de Variables

- **Predictor 1: Autoeficacia Académica.** (Confianza en las propias capacidades).
- **Predictor 2: Procrastinación Académica.** (Tendencia a posponer).
- **Predictor 3: Agotamiento Emocional.** (Burnout académico).
- **Variable Objetivo: Motivación Investigativa.** (Interés en realizar tesis/artículos).

C. Esquema del Modelo y Resultados

Modelo reflectivo estimado con estimador robusto (MLR).



- **H_1: Agotamiento → Motivación.**
 - *Resultado: Rechazada ($p > 0.05$).* El cansancio no mata la motivación; la falta de confianza sí.
- **H_2: Autoeficacia → Motivación.**
 - *Resultado: Aceptada ($\beta = 0.26$).* El predictor positivo más fuerte.
- **H_3: Procrastinación → Motivación.**
 - *Resultado: Aceptada Negativa ($\beta = -0.26$).* Actúa como el contrapeso exacto de la autoeficacia.

- **Idea de Innovación:** Añadir **Inteligencia Artificial** como variable exógena. ¿El uso de herramientas como ChatGPT aumenta la *Autoeficacia* (al facilitar tareas) o aumenta la *Procrastinación*?

9.5 Marketing en Redes Sociales y Segmentación (Enfoque Híbrido SEM + Machine Learning)

Referencia Base: Kim, A. J., & Ko, E. (2012). Do social media marketing activities enhance customer equity? An empirical study of luxury fashion brands. *Journal of Business Research*, 65(10), 1480–1486. (Estudio fundacional adaptado con técnicas modernas de ML).

🔗 **Enlace de Acceso:** <https://doi.org/10.1016/j.jbusres.2011.10.014>

A. Contexto y Objetivo


El marketing en redes sociales (SMM) es una "caja negra" para muchas empresas. Se invierte en contenido, pero no está claro qué atributo específico genera ventas. Este estudio innova al combinar **PLS-SEM** (para probar relaciones causales) con técnicas de **Clustering** (Machine Learning) para identificar qué impulsa la compra en diferentes segmentos de usuarios.

B. Operacionalización de Variables (Modelo SMM)

- **Variables Exógenas (Actividades de Marketing - SMMA):**

1. **Entretenimiento (X₁):** Grado de diversión y placer estético del contenido.
 2. **Interacción (X₂):** Facilidad para comunicar opiniones y recibir respuestas de la marca.
 3. **Tendencia/Trendiness (X₃):** Actualidad de la información (estar "a la moda").
 4. **Personalización (X₄):** Adaptación del mensaje al perfil del usuario.
 5. **Boca a Boca Electrónico - eWOM (X₅):** Recomendaciones de pares.
- Variable Endógena:
 6. **Intención de Compra (Y):** Probabilidad de adquirir el producto tras la exposición en redes.

Modelo Teórico del estudio



C. Esquema del Modelo Estructural y Resultados de Hipótesis

- **H₁: Entretenimiento → Intención de Compra.**
 - *Resultado: Aceptada (Segmento Pasivo).* Para usuarios observadores, el contenido visual es clave.
- **H₂: Interacción → Intención de Compra.**
 - *Resultado: Aceptada (Segmento Activo).* Es el predictor más fuerte ($\beta > 0.40$). En redes sociales, la validación bidireccional pesa más que el contenido estático.
- **H₃: eWOM → Intención de Compra.**
 - *Resultado: Significativa y Positiva.* La confianza se transfiere de usuario a usuario, no de marca a usuario.

D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Replicar este modelo comparando plataformas generacionales: **TikTok (Video corto)** vs. **LinkedIn (Texto profesional)**.
 - *Hipótesis a probar:* En TikTok, el *Entretenimiento* será el predictor dominante (beta alto), mientras que en LinkedIn la *Tendencia/Información* será la variable crítica.

9.6 Gestión del Talento Internacional (Inteligencia Cultural)

Referencia Base: Ang, S., et al. (2007). Cultural Intelligence: Its Measurement and Effects on Cultural Judgment and Decision Making, Cultural Adaptation and Task Performance. *Management and Organization Review*, 3(3), 335-371.


🔗 **Enlace de Acceso:** <https://doi.org/10.1111/j.1740-8784.2007.00082.x>

A. Contexto y Objetivo

La globalización exige gerentes capaces de operar en múltiples culturas. El estudio busca validar empíricamente si la **Inteligencia Cultural (CQ)** es un predictor real del desempeño o si basta con la "Experiencia Internacional" (años viviendo fuera). Es un caso clásico de validación de competencias blandas mediante SEM.

B. Operacionalización de Variables

- **Predictor 1: Inteligencia Cultural (CQ - Segundo Orden):**
 - *Dimensiones:* Metacognitiva, Cognitiva, Motivacional y Conductual.
- **Predictor 2: Experiencia Internacional:** Número de asignaciones en el extranjero.
- **Variable Mediadora: Autoeficacia Intercultural** (Confianza en la propia capacidad de adaptación).
- **Variable Endógena: Desempeño en la Tarea** (Task Performance).



C. Esquema del Modelo y Resultados Clave

- **H₁: CQ → Autoeficacia Intercultural.**
 - *Resultado: Aceptada (\beta alto).* Entender las normas culturales (CQ Cognitivo) reduce la ansiedad y aumenta la confianza.

- **H_2: Experiencia Internacional → Desempeño.**
 - *Resultado: Débil o No Significativa.* Hallazgo contraintuitivo: "Haber viajado mucho" no garantiza el éxito si no se desarrolló inteligencia cultural.
- **H_3 (Mediación): CQ → Autoeficacia → Desempeño.**
 - *Resultado: Mediación Total.* La inteligencia cultural mejora el desempeño *porque* primero aumenta la autoeficacia del gerente.

D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Introducir la variable "**Entorno Virtual**". ¿Es necesaria la Inteligencia Cultural Conductual (lenguaje corporal) cuando se gestionan equipos globales vía Zoom/Teams, o se requiere una nueva "**Inteligencia Digital Cultural**"?

9.7 E-Commerce en Mercados Emergentes (Impulsores vs. Barreras)

Referencia Base: Cabrera-Sánchez, J. P., & Villarejo-Ramos, A. F. (2019). Factors affecting the adoption of mobile commerce: The impact of trust and perceived risk. *Spanish Journal of Marketing - ESIC*. (Adaptado al contexto Ecuador/Latam).

A. Contexto y Objetivo

En Latinoamérica, la adopción del comercio electrónico enfrenta barreras distintas a las de Europa o EE.UU. El miedo al fraude (Riesgo) y la necesidad de "tocar el producto" compiten contra la comodidad. Este estudio usa un modelo de **Balance de Valencias** (Positivo vs. Negativo).


B. Operacionalización de Variables

- **Impulsores (Valencias Positivas):**
 1. **Confianza (X_1):** Seguridad técnica y reputación del vendedor.
 2. **Conveniencia (X_2):** Ahorro de tiempo y esfuerzo (TAM: Facilidad de uso).
- **Barreras (Valencias Negativas):**
 3. **Riesgo Percibido (X_3):** Miedo a pérdida financiera o privacidad.
 4. **Costos de Transacción (X_4):** Envíos, tarifas ocultas.
- **Variable Objetivo: Intención de Compra Online.**

C. Resultados de Hipótesis

- **H_1: Confianza → Intención de Compra.**

- *Resultado: Aceptada y Dominante.* En mercados emergentes, la confianza es una *condición necesaria*. Sin ella, la conveniencia es irrelevante.
- **H_2: Riesgo Percibido → Intención de Compra.**
 - *Resultado: Negativa Significativa.* El riesgo actúa como un freno directo.
- **H_3: Costos → Riesgo Percibido (Efecto Indirecto).**
 - *Resultado: Aceptada.* Costos de envío poco claros aumentan la percepción de que el sitio es "riesgoso" o fraudulento.



D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Comparar **Web Propia vs. Marketplace (Amazon/MercadoLibre)**.

- *Hipótesis*: En Marketplaces, la "Confianza" ya está dada por la plataforma, por lo que la variable crítica pasa a ser la "Conveniencia". En webs propias, la "Confianza" sigue siendo la barrera #1.

9.8 E-Commerce y Moda en Mercados Emergentes (Análisis de Barreras y Motivadores)

Referencia Base: Margalina, V. M., Jiménez-Sánchez, Á., y Cutipa-Limache, A. M. (2024). Modelo PLS-SEM para la intención de compra online en el sector moda en Ecuador. *Retos Revista de Ciencias de la Administración y Economía*, 14(27), 101-114.

🔗 **Enlace de Acceso:** <https://doi.org/10.17163/ret.n27.2024.07>

A. Contexto y Objetivo

El comercio electrónico en Latinoamérica experimentó un auge post-pandemia, pero el sector moda enfrenta una barrera única: la necesidad sensorial ("tocar la ropa"). Este estudio, realizado con una muestra de 384 *millennials* en Ecuador, utiliza PLS-SEM para desenmarañar cómo interactúan los impulsores de la compra (Confianza, Conveniencia) frente a sus frenos (Riesgo, Costos). Es un ejemplo magistral de cómo modelar comportamientos de consumo en economías en desarrollo.

B. Operacionalización de Variables

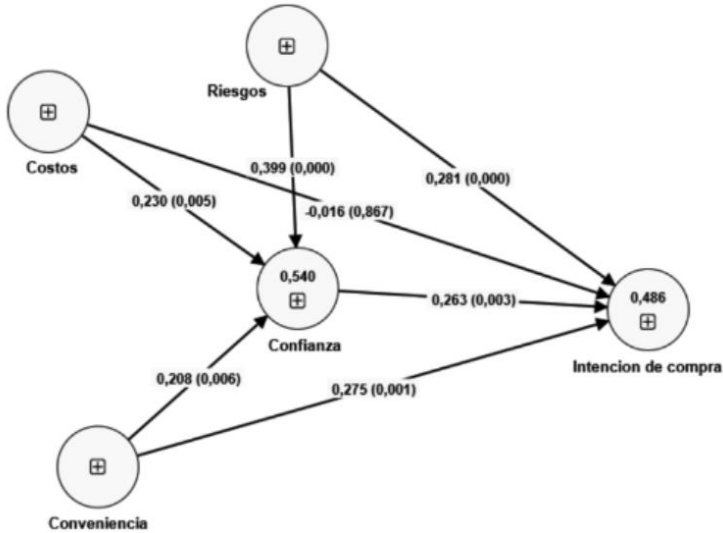
El modelo estructural opone variables positivas contra negativas para explicar la **Intención de Compra (IC)**:

- **Variables Exógenas (Independientes):**
 1. **Confianza (CON):** Seguridad percibida en la plataforma y honestidad del vendedor.
 2. **Conveniencia (CO):** Facilidad de uso, ahorro de tiempo y disponibilidad 24/7.
 3. **Costos de Transacción (CT):** Gastos de envío, tarifas ocultas y tiempo de espera.
- **Variables Endógenas (Mediadora y Final):**
 4. **Riesgo Percibido (RP):** Incertidumbre sobre la calidad del producto o seguridad de los datos.
 5. **Intención de Compra (IC):** Probabilidad declarada de realizar transacciones futuras.

C. Esquema del Modelo y Hallazgos Clave

El estudio validó un modelo donde los costos no frenan la compra directamente, sino que "asustan" al consumidor (aumentan el riesgo).

- *Resultado: Aceptada (beta = 0.468, p < 0.001).*
- *Hallazgo: Es el predictor más potente. En mercados con baja institucionalidad, la confianza lo es todo.*
- **H_2: Conveniencia → Intención de Compra.**
 - *Resultado: Aceptada (beta = 0.297, p < 0.001).*
- **H_3: Riesgo Percibido → Intención de Compra.**
 - *Resultado: Aceptada Negativa (beta = -0.134, p < 0.005). El miedo reduce la intención, pero menos de lo esperado.*
- **H_4 y H_5 (La Ruta de los Costos):**
 - *Directo: Costos → Intención (beta = -0.046, No Significativo).*
 - *Indirecto: Costos → Riesgo Percibido (beta = 0.457, Significativo).*
 - *Lección Metodológica: Los costos altos no hacen que la gente "no quiera comprar"; hacen que la gente "desconfíe". Es un efecto mediado total.*



D. Valor para la Replicación/Innovación

- **Para el Investigador:** Este diseño es ideal para replicar en otros sectores de "alto contacto" (ej. Muebles, Autos).
- **Idea de Innovación:** Introducir la variable "**Realidad Aumentada (AR)**" como moderadora.
 - *Hipótesis:* El uso de probadores virtuales (AR) debilitará la relación negativa entre *Riesgo Percibido* e *Intención de Compra*, haciendo que el riesgo de "talla incorrecta" desaparezca.

9.9 Arquitectura Empresarial y Transformación Digital

Referencia Base: Ross, J. W., Weill, P., & Robertson, D. C. (2006). *Enterprise Architecture as Strategy*. (Validación empírica mediante PLS-SEM de los conceptos de alineación estratégica).

 **Enlace de Acceso (Concepto Base):**

<https://hbr.org/2005/01/implementing-enterprise-architecture-putting-the-plan-into-action>


A. Contexto y Objetivo

Muchas iniciativas de Transformación Digital fracasan por falta de alineación. Se compra tecnología moderna sobre procesos antiguos. Este caso utiliza **Constructos Formativos** para modelar la "Arquitectura Empresarial" y medir su impacto en la agilidad del negocio.

B. Operacionalización de Variables (Enfoque Formativo)

- **Constructo Formativo 1: Arquitectura de Negocio (X_1):** Estandarización de procesos, integración de datos de clientes, optimización de flujos.
- **Constructo Formativo 2: Arquitectura Tecnológica (X_2):** Nube, modularidad, APIs, ciberseguridad.
- **Variable de Interacción: Alineación (Fit) (X_1 → X_2).**

- **Variable Endógena: Éxito de la Transformación Digital** (Agilidad, Time-to-Market).



C. Resultados de Hipótesis Estructurales

- **H_1: Arquitectura Tecnológica → Éxito Digital.**
 - *Resultado: Bajo o No Significativo.* La tecnología por sí sola no transforma nada.
- **H_2: Alineación (Interacción) → Éxito Digital.**
 - *Resultado: Alta y Significativa.* El éxito depende de qué tan bien encaja la tecnología con los procesos estandarizados.
- **H_3: Arquitectura → Eficiencia vs. Innovación.**

- *Resultado:* Una arquitectura rígida mejora la Eficiencia (costos) pero puede tener un efecto negativo en la Innovación Radical (flexibilidad).

D. Valor para la Replicación/Innovación

- **Idea de Innovación:** Evaluar el impacto de la **Inteligencia Artificial Generativa** en la arquitectura.
 - *Pregunta:* ¿La adopción de IA requiere una arquitectura de datos más estricta (para entrenar modelos limpios) o una más flexible? Modelar "Gobernanza de Datos" como mediador.

9.10 Síntesis global

La siguiente matriz sistematiza los nueve casos analizados en este capítulo, clasificándolos según el Nivel de Análisis (Validación, Comportamiento, Disrupción, Complejidad) y el Enfoque Metodológico principal. Esta herramienta sirve como guía rápida para que investigadores y tesisistas identifiquen qué arquitectura de modelo SEM se adapta mejor a sus preguntas de investigación.

Tabla 33

Síntesis de Casos y Tipología de Uso del SEM

Nivel de Análisis	Caso de Estudio	Sector / Industria	Enfoque Metodológico Clave	Lección Gerencial Principal ("El Insight")
1. VALIDACIÓN (Confirmar Teoría)	Caso 1: Cadena de Suministro (Wisner)	Manufactura / Logística	Mediación Total	La integración con proveedores no genera rentabilidad por sí sola; debe traducirse en una estrategia SCM interna cohesiva.
	Caso 2: Marketing Salud (Djan & Fitriyanti)	Salud / Dispositivos	Efectos Directos (Marketing Mix)	En sectores sensibles, la Información (Promoción) supera a la Ubicación (Plaza). Priorizar comunicación sobre infraestructura física.
2. COMPORTAMIENTO (Entender al Humano)	Caso 4: Motivación (Carranza et al.)	Educación Superior	Predicción Psicológica	El estrés (Burnout) no frena el desempeño; la falta de confianza (Autoeficacia) y la postergación (Procrastinación) sí lo hacen.
	Caso 6: Talento Global (Ang et al.)	RR.HH. / Internacional	Mediación de Competencias	La experiencia internacional ("haber viajado") no garantiza el éxito. La Inteligencia Cultural es el verdadero mediador del desempeño.
3. DISRUPCIÓN (Mercados Digitales)	Caso 5: Redes Sociales (Kim & Ko)	Moda de Lujo	Híbrido (SEM + Clustering)	Segmentación conductual: Los usuarios pasivos buscan entretenimiento visual; los activos buscan interacción y respuesta rápida.

Nivel de Análisis	Caso de Estudio	Sector / Industria	Enfoque Metodológico Clave	Lección Gerencial Principal ("El Insight")
	Caso 7: E-Commerce Latam (Cabrera & Villarejo)	Retail General	Balance de Valencias	La Confianza es un "Gatekeeper". Si no se supera el umbral de seguridad, la Conveniencia del sitio web es irrelevante.
	Caso 8: Moda Online Ecuador (Margalina et al.)	Moda / Mercados Emergentes	Mediación de Riesgo	Los costos altos no frenan la compra directamente, sino que aumentan el Riesgo Percibido. El consumidor no dice "es caro", dice "no me fío".
4. COMPLEJIDAD (Sistemas Avanzados)	Caso 3: Riesgo Crediticio (Junianto et al.)	Banca / Finanzas	No Lineal / Semiparamétrico	Paradoja de la liquidez: Clientes con mayor capacidad de pago pueden ser menos puntuales debido a la diversificación de fondos.
	Caso 9: Arq. Empresarial (Ross et al.)	Tecnología / TI	Modelos Formativos / Interacción	Comprar tecnología sin estandarizar procesos (Arquitectura de Negocio) es ineficaz. El éxito depende de la Alineación (Fit) entre ambos.

Fuente: Elaboración basada en la revisión de la literatura (2025).

Tres lecciones metodológicas para el investigador.

De la síntesis de estos casos se derivan tres principios rectores para quienes deseen innovar utilizando SEM:

1. **El Contexto Modifica el Modelo (Validez Ecológica):** Lo que funciona en EE. UU. (donde la confianza en el e-commerce es alta) no funciona igual en Ecuador o Perú (donde la confianza es una barrera crítica, como vimos en el Caso 7). *Recomendación:* No replique modelos ciegamente; introduzca variables moderadoras culturales o económicas propias de su región.
2. **La Linealidad es una Ilusión:** El Caso 3 (Banca) nos enseñó que las relaciones humanas y financieras no siempre son líneas rectas. A veces, "más dinero" no significa "mejor pago". *Recomendación:* Atrévase a explorar relaciones no lineales (cuadráticas) o segmentadas en sus modelos PLS-SEM.
3. **La Mediación es el "Porqué":** Los modelos más potentes (Casos 1, 6 y 8) no se conformaron con ver si "X afecta a Y". Buscaron el "cómo". La integración SCM, la Autoeficacia o la Alineación Tecnológica son las "cajas negras" que el SEM permitió abrir. *Recomendación:* Sus modelos siempre deben intentar responder *por qué* sucede un fenómeno, no solo *si* sucede.

Conclusión

El análisis transversal de estos nueve casos revela que el Modelado de Ecuaciones Estructurales (SEM) es mucho más que una técnica estadística de validación; es un lente estratégico.

1. **Versatilidad:** Hemos visto su aplicación desde la psicología de un estudiante hasta la arquitectura tecnológica de una multinacional.
2. **Rigor:** Permite desafiar supuestos "obvios" (como que más dinero implica mejor pago, Caso 3) y descubrir verdades ocultas (como que el Burnout no afecta la motivación, Caso 4).
3. **Adaptabilidad:** Los casos de Ecuador (Caso 8) y Latam (Caso 7) demuestran la importancia de adaptar los modelos al contexto cultural, donde variables como la *Confianza* juegan roles distintos a los de mercados desarrollados.

Para el investigador que inicia su camino, la recomendación es clara: no reinvente la rueda. Utilice estos casos como plantillas arquitectónicas, adáptelos a su realidad local e innove introduciendo nuevas variables moderadoras (como IA o Realidad Aumentada) que respondan a los desafíos del futuro

Así mismo como hemos visto a través de estos casos, el éxito no radica en la complejidad matemática del modelo, sino en la calidad de la pregunta de investigación. El software (R, SmartPLS, AMOS) es solo

el vehículo; la teoría sustantiva y el conocimiento del contexto son el motor.

Referencias:

- Al-Ghazali, B. (2024). Navigating the Digital Landscape: Factors Shaping Entrepreneurial Dynamics in Saudi Arabia. *Retos*, 14(27), 85-99. <https://doi.org/10.17163/ret.n27.2024.06>
- Carranza Esteban, R. & others. (2024). Emotional exhaustion, academic self-efficacy, and academic procrastination as predictors of research motivation. *Frontiers in Education*, 9, Article 1147599.
- Ebrahimi, P., Basirat, M., Yousefi, A., Nekmahmud, M., Gholampour, A., & Fekete-Farkas, M. (2022). Social networks marketing and consumer purchase behavior: The combination of SEM and unsupervised machine learning approaches. *Big Data and Cognitive Computing*, 6(2), 35. <https://doi.org/10.3390/bdcc6020035>
- Ismulyana Djan, I., & Fitriyanti, F. (2017). The analysis of price, promotion, and place and their effect on consumer decision making: A study of structural equation modeling in healthcare products. *The Management Journal of BINANIAGA*, 2(2), 87-104.
- Junianto, J., Fernandes, A., Solimun, S., & Hamdan, H. (2023). Structural equation modeling semiparametric in modeling the accuracy of payment time for customers of credit bank in Indonesia. *Jurnal Teknik dan Manajemen Industri*, 9(2), 142-154.
- Margalina, V. M., Jiménez-Sánchez, [completar], & Cutipa-Limache, A. M. (2024). Determinants of online purchase intention in the fashion sector: Evidence from Ecuador using PLS-SEM. *Retos: Revista de*

Ciencias de la Administración y Economía, 14(27), 101-114.
<https://doi.org/10.17163/ret.n27.2024.06>

OHiggins, D. (2023). Impacts of business architecture in the context of digital transformation: An empirical study using PLS-SEM approach. *Journal of Business and Management Studies*, 5(4), 72-84.
<https://doi.org/10.32996/jbms.2023.5.4.7>

Wawrosz, P., & Jursek, M. (2021). Developing intercultural efficiency: The relationship between cultural intelligence and self-efficacy. *Social Sciences*, 10(8), 312. <https://doi.org/10.3390/socsci10080312>

Wisner, J. D. (2003). A structural equation model of supply chain management strategies and firm performance. *Journal of Supply Chain Management*, 39(3), 15-28. <https://doi.org/10.1002/j.2158-1592.2003.tb00030.x>

Referencias de casos:

- Ballen, C. J., & Salehi, S. (2021). Mediation Analysis in Discipline-Based Education Research Using Structural Equation Modeling: Beyond “What Works” to Understand How It Works, and for Whom. *Journal of Microbiology & Biology Education*, 22(2), e00108-21.
<https://doi.org/10.1128/jmbe.00108-21>
- Byrne, B. M. (2016). *Structural Equation Modeling With AMOS: Basic Concepts, Applications, and Programming, Third Edition* (0 ed.). Routledge.
<https://doi.org/10.4324/9781315757421>
- Campos, L. A. G., Quijaite, J. J. S., & Huamaní, P. L. T. (2020). Modelo SEM basado en valores organizacionales y capital intelectual: Un estudio realizado en entidades del sistema financiero peruano. *Retos*, 10(19), 5–28.
<https://doi.org/10.17163/ret.n19.2020.01>
- Cao, G., & Weerawardena, J. (2023). Strategic use of social media in marketing and financial performance: The B2B SME context. *Industrial Marketing Management*, 111, 41–54.
<https://doi.org/10.1016/j.indmarman.2023.03.007>
- Changalima, I. A., & Elias, R. (2024). Mediating effect of purchasing efficiency on the relationship between purchasing analytical skills and restaurant performance: A PLS-SEM approach. *Journal of Money and Business*, 4(2), 138–149.
<https://doi.org/10.1108/JMB-11-2022-0058>
- Dash, G., & Paul, J. (2021). CB-SEM vs PLS-SEM methods for research in social sciences and technology forecasting. *Technological Forecasting and Social Change*, 173, 121092.
<https://doi.org/10.1016/j.techfore.2021.121092>

- Elangovan N, & R, R. (2015). *Structural equation modeling-A second-generation multivariate analysis*. <https://doi.org/10.13140/RG.2.1.4837.4885>
- Gefen, D., Straub, D., & Boudreau, M.-C. (2000). Structural Equation Modeling and Regression: Guidelines for Research Practice. *Communications of the Association for Information Systems*, 4. <https://doi.org/10.17705/1CAIS.00407>
- 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. <https://doi.org/10.1016/j.indmarman.2023.03.010>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., Sarstedt, M., Danks, N. P., & Ray, S. (2021). Evaluation of Formative Measurement Models. En J. F. Hair Jr., G. T. M. Hult, C. M. Ringle, M. Sarstedt, N. P. Danks, & S. Ray (Eds.), *Partial Least Squares Structural Equation Modeling (PLS-SEM) Using R: A Workbook* (pp. 91–113). Springer International Publishing. https://doi.org/10.1007/978-3-030-80519-7_5
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). *PLS-SEM: Indeed a Silver Bullet* (SSRN Scholarly Paper No. 1954735). Social Science Research Network. <https://papers.ssrn.com/abstract=1954735>
- Henseler, J., Ringle, C. M., & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. En R. R. Sinkovics & P. N. Ghauri (Eds.), *Advances in International Marketing* (Vol. 20, pp. 277–319). Emerald Group Publishing Limited. [https://doi.org/10.1108/S1474-7979\(2009\)0000020014](https://doi.org/10.1108/S1474-7979(2009)0000020014)

Ikram, A. A. D. W., Salam, M., At, M. R., & Muhammad, S. (2025). Employing Structural Equation Modeling to Examine the Determinants of Work Motivation and Performance Management in BUMDES: In Search of Key Driver Factors in Promoting Sustainable Rural Development Strategies. *Sustainability*, 17(15), 6855. <https://doi.org/10.3390/su17156855>

Introducción al modelado de ecuaciones estructurales (SEM) en R con lavaan. (s. f.). Recuperado 15 de noviembre de 2025, de <https://stats.oarc.ucla.edu/r/seminars/rsem/>

Khin, S., & Ho, T. C. (2019). Digital technology, digital capability and organizational performance: A mediating role of digital innovation. *International Journal of Innovation Science*, 11(2), 177–195. <https://doi.org/10.1108/IJIS-08-2018-0083>

Legate, A. E., Ringle, C. M., & Hair, J. F. (2024). PLS-SEM: A method demonstration in the R statistical environment. *Human Resource Development Quarterly*, 35(4), 501–529. <https://doi.org/10.1002/hrdq.21517>

Lin, S.-K., & Chung, H.-C. (2023). The Relationship Between Entrepreneurial Orientation and Firm Performance From the perspective of MASEM: The Mediation Effect of Market Orientation and the Moderated Mediation Effect of Environmental Dynamism. *Sage Open*, 13(4), 21582440231218804. <https://doi.org/10.1177/21582440231218804>

Liu, Z., Yan, M., Fan, Y., & Chen, L. (2021). Ascribed or achieved? The role of birth order on innovative behaviour in the workplace. *Journal of Business Research*, 134, 480–492. <https://doi.org/10.1016/j.jbusres.2021.05.058>

- Lozano Bolívar, J. G. (2025). Modelo de ecuaciones estructurales para la evaluación de competencias transversales en tecnólogos del sena en Bogotá. *Ciencia Latina Revista Científica Multidisciplinar*, 9(2), 496–532. https://doi.org/10.37811/cl_rcm.v9i2.16861
- Margalina, V. M., Jiménez-Sánchez, [completar], & Cutipa-Limache, A. M. (2024). Determinants of online purchase intention in the fashion sector: Evidence from Ecuador using PLS-SEM. *Retos: Revista de Ciencias de la Administración y Economía*, 14(27), 101–114. <https://doi.org/10.17163/ret.n27.2024.06>
- Martínez Ávila, M., & Fierro Moreno, E. (2018). Aplicación de la técnica PLS-SEM en la gestión del conocimiento: Un enfoque técnico práctico / Application of the PLS-SEM technique in Knowledge Management: a practical technical approach. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 8(16), 130–164. <https://doi.org/10.23913/ride.v8i16.336>
- Meza Bernaola, E. C., Quiñones Peinado, F., & Torres López, C. A. (2023). Modelamiento mediante ecuaciones estructurales (PLS-SEM) de factores clave de la transformación digital. *Contabilidad y Negocios*, 18(36), 15–36. <https://doi.org/10.18800/contabilidad.202302.006>
- Oliveira, H. H., & Honório, L. C. (2020). Human resources practices and organizational commitment: Connecting the constructs in a public organization. *RAM. Revista de Administração Mackenzie*, 21, eRAMG200160. <https://doi.org/10.1590/1678-6971/eRAMG200160>
- Palacios Posadas, V. M., Pietro Sosa Macassi, S. P., & Chávez Vera, K. J. (2024). *Explorando la relación entre la formación y el*

desempeño empresarial de gestores de microempresas. Zenodo. <https://doi.org/10.5281/ZENODO.13774325>

PLS-SEM CPM in R. (2022). <https://osf.io/jhcx4>

Preacher, K. J., Rucker, D. D., & Hayes, A. F. (2007). Addressing moderated mediation hypotheses: Theory, methods, and prescriptions. *Multivariate Behavioral Research*, 42(1), 185–227. <https://doi.org/10.1080/00273170701341316>

Quantitative Data Analysis for Language Assessment Volume II: Advanced Methods. (s. f.). Routledge & CRC Press. Recuperado 14 de noviembre de 2025, de <https://www.routledge.com/Quantitative-Data-Analysis-for-Language-Assessment-Volume-II-Advanced-Methods/Aryadoust-Raquel/p/book/9781032091440>

Raeisi, S., Lingjie, M., & Suhaili Binti Ramli, N. (2019). A Hierarchical Model of Mediation Effect of Motivation (MO) between Internal Marketing (IM) and Service Innovation (SI). *Administrative Sciences*, 9(4), 85. <https://doi.org/10.3390/admsci9040085>

Sandoval-Álvarez, C. (2024). Análisis de mediación moderada mediante ecuaciones estructurales: Un enfoque para investigaciones en gestión de empresas. *Yulök Revista de Innovación Académica*, 8(1), 31–46. <https://doi.org/10.47633/xv3dqm39>

Sarstedt, M., Hair, J. F., Nitzl, C., Ringle, C. M., & Howard, M. C. (2020). Beyond a tandem analysis of SEM and PROCESS: Use of PLS-SEM for mediation analyses! *International Journal of Market Research*, 62(3), 288–299. <https://doi.org/10.1177/1470785320915686>


- Soriano, J. L., & Mejía-Trejo, J. (2022). Modelado de ecuaciones estructurales en el campo de las Ciencias de la Administración. *Revista de Métodos Cuantitativos para la Economía y la Empresa*. <https://doi.org/10.46661/revmetodoscuanteconempresa.5414>
- Suder, M., Kusa, R., Duda, J., & Okręglicka, M. (2025). Mediating or moderating? Innovative approach to the role of flexibility in the relationship between entrepreneurial orientation and firm growth under different market conditions. *Journal of Innovation & Knowledge (JIK)*, 10(2), 1–19. <https://doi.org/10.1016/j.jik.2025.100658>
- Uslu, A., & Şengün, H. İ. (2021). The multiple mediation roles of trust and satisfaction in the effect of perceived corporate social responsibility on loyalty. *Business, Management and Economics Engineering*, 19(01), 49–69. <https://doi.org/10.3846/bmee.2021.13362>
- Vuttichat, S., & Patchara, P. (2023). *Causal relationship model of marketing innovation and competitiveness of small and medium enterprises (SMEs) with digital technologies in Thailand*. F1000Research. <https://doi.org/10.12688/f1000research.138941.2>
- Wawrosz, P., & Jurásek, M. (2021). Developing Intercultural Efficiency: The Relationship between Cultural Intelligence and Self-Efficacy. *Social Sciences*, 10(8), 1–21.
- Zúñiga, E. J. P., Guale, L. N., Mediavilla, K. M. J., & Nuñez, E. R. V. (2025). Ecuaciones Estructurales Aplicadas a la Toma de Decisiones: Análisis Estadístico en Gestión Empresarial y Comportamiento del Consumidor. *Reincisol.*, 4(8), 2380–2405. [https://doi.org/10.59282/reincisol.V4\(8\)2380-2405](https://doi.org/10.59282/reincisol.V4(8)2380-2405)

EPÍLOGO

El análisis estructural en las ciencias empresariales ha experimentado un avance significativo en las últimas décadas, impulsado por la necesidad de comprender fenómenos organizacionales cada vez más complejos y dinámicos. Este libro ha buscado contribuir a ese avance ofreciendo una visión metodológica integral, rigurosa y contemporánea del Modelado de Ecuaciones Estructurales (SEM), articulando fundamentos teóricos, procedimientos operativos y aplicaciones prácticas que fortalecen la capacidad analítica de los investigadores y profesionales del sector.

A lo largo de los capítulos, el SEM se ha presentado no solo como una técnica estadística, sino como una arquitectura conceptual y analítica que permite construir explicaciones sólidas, evaluar teorías, identificar mecanismos causales y proyectar escenarios futuros con sustento empírico. Desde los modelos de medida reflexivos y formativos hasta los análisis interaccionales y predictivos, cada componente analizado aporta herramientas que permiten abordar preguntas de investigación estratégicas, relevantes y alineadas con los desafíos actuales del entorno empresarial.

El compromiso con la ciencia abierta, la reproducibilidad y el uso de software especializado constituye uno de los pilares centrales de esta propuesta. En un contexto donde los datos se han convertido en un recurso estratégico, la transparencia metodológica y la capacidad de replicar modelos son condiciones indispensables para garantizar la calidad y la credibilidad de los hallazgos científicos. Por ello, la integración de



plataformas como R, lavaan, seminr, SmartPLS y AMOS no se presenta como una simple elección técnica, sino como un componente esencial para consolidar una cultura de investigación robusta y sostenible.

Los casos de estudio expuestos muestran cómo el SEM puede ser aplicado con pertinencia en distintos sectores de la economía, evidenciando su valor para comprender dinámicas de mercado, comportamiento del consumidor, desempeño organizacional, innovación, gestión del talento y transformación digital. Estos casos buscan inspirar nuevas líneas de investigación y promover la aplicación de metodologías avanzadas en contextos reales, con una perspectiva que conjuga teoría, evidencia y visión estratégica.

Al cerrar esta obra, se invita al lector a continuar explorando, cuestionando y perfeccionando el uso del SEM como herramienta de investigación avanzada. La ciencia empresarial seguirá enfrentando retos derivados de la digitalización, la globalización y los cambios estructurales en los mercados; por ello, la capacidad para modelar, analizar y predecir fenómenos complejos seguirá siendo una competencia esencial. Este libro aspira a ser un punto de partida y a la vez una guía permanente para quienes desean fortalecer su pensamiento analítico y contribuir al desarrollo científico y organizacional.

Finalmente, más allá de los métodos y modelos presentados, este libro pretende fomentar una actitud investigativa rigurosa, ética y orientada al impacto. La generación de conocimiento no es un fin en sí mismo, sino

un proceso continuo que busca transformar realidades y generar valor para la sociedad. Que estas páginas sirvan como estímulo para avanzar por ese camino con determinación, compromiso y excelencia académica.

GLOSARIO

Término	Definición
Análisis Factorial Confirmatorio (CFA)	Técnica para comprobar si los indicadores se agrupan como se espera en función de los constructos latentes.
Bondad de Ajuste Global (GOF)	Índices que resumen el grado de ajuste entre el modelo teórico y los datos observados.
Cargas Factoriales	Medida de la correlación entre un indicador y su constructo latente.
Coefficiente de Determinación (R ²)	Proporción de la varianza en la variable dependiente explicada por las variables independientes del modelo.
Colinealidad	Problema en el que dos o más indicadores están altamente correlacionados, dificultando la estimación precisa de sus efectos.
Constructo Latente	Variable no observable medida a través de indicadores (ejemplo: satisfacción, compromiso).
FIMIX-PLS	Algoritmo para detectar y estimar la existencia de segmentos latentes y modelar heterogeneidad no observada.
Indicador	Variable observable utilizada para medir un constructo latente.
Inner Model (Modelo Estructural)	Submodelo de SEM que representa relaciones causales entre constructos latentes.
Lo-Mendell-Rubin (LMR)	Test estadístico que ayuda a determinar el número óptimo de segmentos latentes en un modelo de mezcla finita.
Mediación	Proceso mediante el cual el efecto de una variable sobre otra es transmitido a través de un constructo intermedio.
MICOM	Protocolo para evaluar si los constructos se miden de igual forma en diferentes grupos antes de realizar comparaciones multigrupo.

Modelado de Ecuaciones Estructurales (SEM)	Técnica estadística multivariante que analiza simultáneamente relaciones entre variables latentes y observadas.
Modelo de Medida Formativo	Esquema en el que los indicadores definen y establecen el significado del constructo.
Modelo de Medida Reflexivo	Esquema en el que los indicadores son consecuencia del constructo y reflejan su existencia.
Multicolinealidad	Situación donde varios indicadores tienen altos niveles de correlación entre sí, influyendo negativamente en la interpretación de los resultados.
Outer Model (Modelo de Medida)	Submodelo de SEM que describe cómo los indicadores miden cada constructo latente.
PLS-POS	Algoritmo de segmentación que prioriza la maximización de la capacidad predictiva sobre el constructo objetivo.
Q ² (Relevancia Predictiva)	Métrica que mide la precisión de la predicción fuera de muestra realizada por el modelo.
Segmentación Latente	Identificación de grupos ocultos basados en patrones estructurales o causales no explicados por variables observadas tradicionales.
SEM	Abreviatura de Modelado de Ecuaciones Estructurales.
SmartPLS	Software especializado para la estimación y validación de modelos PLS-SEM.
Validación Cruzada	Procedimiento estadístico que evalúa la estabilidad y capacidad predictiva de un modelo en subconjuntos distintos de una base de datos.

ACRÓNIMOS

Acrónimo	Significado
SEM	Modelado de Ecuaciones Estructurales (Structural Equation Modeling)
CB-SEM	SEM basado en Covarianzas (Covariance-Based SEM)
PLS-SEM	SEM basado en Mínimos Cuadrados Parciales (Partial Least Squares SEM)
AVE	Varianza Extraída Promedio (Average Variance Extracted)
VIF	Factor de Inflación de la Varianza (Variance Inflation Factor)
CVI	Índice de Validez de Contenido (Content Validity Index)
AJI	Acuerdo Inter-Jueces (Inter-Judge Agreement)
MGA	Análisis Multigrupo (Multi-Group Analysis)
LMR	Prueba de Razón de Verosimilitud de Lo-Mendell-Rubin (Lo-Mendell-Rubin Likelihood Ratio Test)
BLRT	Prueba Bootstrap de Razón de Verosimilitud (Bootstrapped Likelihood Ratio Test)
FIMIX-PLS	Mezcla Finita PLS (Finite Mixture Partial Least Squares)
PLS-POS	Segmentación Orientada a Predicciones para Mínimos Cuadrados Parciales (Prediction-Oriented Segmentation)
Q ²	Relevancia Predictiva (Stone-Geisser's Q ²)
CFA	Análisis Factorial Confirmatorio (Confirmatory Factor Analysis)
SRMR	Raíz Cuadrática Media Estándar Residual (Standardized Root Mean Square Residual)
NFI	Índice de Ajuste Normado (Normed Fit Index)
BIC	Criterio de Información Bayesiano (Bayesian Information Criterion)
AIC	Criterio de Información de Akaike (Akaike Information Criterion)
CAIC	Criterio Consistente de Información de Akaike (Consistent Akaike Information Criterion)

Acrónimo	Significado
GOF	Bondad de Ajuste Global (Goodness-of-Fit)
MICOM	Invariancia de la Medición en Modelos Compuestos (Measurement Invariance of Composite Models)
CTA-PLS	Análisis Confirmatorio de Tétradas para PLS (Confirmatory Tetrad Analysis for PLS)
RMSE	Raíz Cuadrada Media del Error (Root Mean Square Error)
MAE	Error Absoluto Medio (Mean Absolute Error)
SC	Costes de Cambio (Switching Costs)
CA	Capacidad de Absorción (Absorptive Capacity)
SCM	Gestión de la Cadena de Suministro (Supply Chain Management)
ERP	Planificación de Recursos Empresariales (Enterprise Resource Planning)
BSC	Balanced Scorecard
IA	Inteligencia Artificial
LISREL	Linear Structural Relations (software SEM)
AMOS	Analysis of Moment Structures (software SEM)
EQS	Equations Structural (software SEM)
Mplus	Software especializado para análisis estructural con múltiples opciones avanzadas
R	Lenguaje de programación estadística ampliamente usado para SEM (lavaan, sem, OpenMx, etc.)
PCA	Análisis de Componentes Principales (Principal Component Analysis)



Autor



Manuel Anchapuri Q.

Es investigador en ciencias empresariales y sociales, especializado en estadística aplicada, modelos SEM, big data y gestión pública. Con amplia trayectoria académica y profesional, ha contribuido al desarrollo de metodologías innovadoras para la investigación. Su labor docente y científica se refleja en esta obra, concebida para impulsar el pensamiento analítico y la excelencia metodológica.

manchapuri@unap.edu.pe



El uso de la analítica se está acelerando, y eso implica más decisiones basadas en datos y menos corazonadas.” — The Science of Successful Organizational Change

Aplicación de modelos de ecuaciones estructurales: Para ciencias empresariales

El Modelado de Ecuaciones Estructurales (SEM) es indispensable para analizar fenómenos organizacionales complejos en gestión, finanzas, marketing y transformación digital. Esta obra ofrece una guía integral: desde fundamentos epistemológicos hasta aplicaciones prácticas de modelos reflexivos, formativos, estructurales e interaccionales.

Incluye criterios decisionales, protocolos de validación predictiva, software especializado y ciencia abierta, más casos reales que explican relaciones causales y fundamentan decisiones gerenciales basadas en datos.

Dirigido a investigadores, docentes, profesionales empresariales, estudiantes de posgrado y consultores que buscan competencias analíticas de alto impacto.

ISBN: 978-612-03-1882-9

