



Modelo de ecuaciones estructurales como herramienta de investigación©

**Manuel Anchapuri Quispe
Fredy Quispe Gómez
Carlos Fuentes Guizado
Héctor Efraín Flores Ortega
Alberto Catachura Vilca**

**Manuel Anchapuri Quispe
Fredy Quispe Gómez
Carlos Fuentes Guizado
Héctor Efraín Flores Ortega
Alberto Catachura Vilca**

**Modelo de ecuaciones estructurales
como herramienta de investigación:
Aplicaciones prácticas y estrategias analíticas en
ciencias empresariales y sociales©**

Modelo de ecuaciones estructurales como herramienta de investigación: Aplicaciones prácticas y estrategias analíticas en ciencias empresariales y sociales©

Autores:

©Fredy Quispe Gómez

©Carlos Fuentes Guizado

©Héctor Efraín Flores Ortega

©Alberto Catachura Vilca

©Manuel Anchapuri Quispe

Editor

©Manuel Anchapuri Quispe

Av. La torre Nro 773

manchapuri@unap.edu.pe

Puno – Perú

Primera edición, noviembre de 2024

Versión digital

DEPÓSITO LEGAL DEL LIBRO ELECTRÓNICO N° 2024-12610

ISBN N° 978-612- 03-0367-2

Disponible en: <https://krmperu.com/web/publicaciones/>

Diseño y diagramación

Micol Zayetsy Anchapuri Ramos

Diseño de cubierta:

Manuel Anchapuri Q.

Modelo de ecuaciones estructurales como herramienta de investigación©

Manuel Anchapuri Quispe

Fredy Quispe Gómez

Carlos Fuentes Guizado

Héctor Efraín Flores Ortega

Alberto Catachura Vilca

“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,

"Elecciones fáciles, vida difícil. Elecciones difíciles, vida fácil" Jerzy Gregorek

Dedicatoria:

A los curiosos, a los persistentes y a los que no temen adentrarse en la complejidad de los Modelos de Ecuaciones Estructurales, les dedicamos este trabajo. Que encuentren en estas páginas no solo fórmulas y métodos, sino también la inspiración para seguir explorando, cuestionando y mejorando. Porque cada investigador que avanza, eleva el conocimiento colectivo y abre nuevas puertas al futuro.

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".*

Índice

Índice	8
Capítulo 1: Origen y Evolución de SEM en Ciencias Empresariales y Sociales	14
Capítulo 2: Importancia de SEM en Ciencias Empresariales y Sociales	21
Capítulo 3: Variables Latentes y Observadas	37
Capítulo 4: Modelo de Medición	60
Capítulo 5: Modelo Estructural	76
Capítulo 6: Recopilación y Preparación de Datos	90
Capítulo 7: Evaluación y Ajuste de Modelos SEM	105
Capítulo 8: Ecosistema de Software para SEM: Herramientas de Acceso Libre y Premium.	118
Capítulo 9: Marketing y Comportamiento del Consumidor	124
Capítulo 10: Recursos Humanos y Comportamiento Organizacional	133
Capítulo 11: Psicología Social y Bienestar	138
Capítulo 12: Educación y Evaluación de Programas Educativos	142
Capítulo 13: Casos Internacionales de SEM en Empresas Latinoamericanas	151
Capítulo 14: Aplicaciones en Contextos Interculturales	156
Capítulo 15: SEM y Ciencia de Datos	165
Capítulo 16: Aplicaciones Prácticas para realizar SEM	175
Acrónimos	195
Bibliografía	203

INTRODUCCIÓN

En el vertiginoso mundo de la investigación científica, particularmente en las Ciencias Empresariales y Sociales, el Modelo de Ecuaciones Estructurales (SEM, por sus siglas en inglés) se destaca como una herramienta avanzada y transformadora. Esta técnica estadística multivariada ha revolucionado la forma en que los investigadores abordan y comprenden las complejas relaciones entre variables observables y latentes, superando limitaciones inherentes a métodos tradicionales como la regresión múltiple y el análisis factorial. La metodología SEM permite, de manera única, la prueba empírica de teorías que implican múltiples niveles de interacción, capturando las conexiones causales y de dependencia entre variables con un grado de precisión y profundidad que hasta hace poco resultaba inalcanzable (Kline, 2011).

Los modelos SEM no solo facilitan el análisis de relaciones entre variables observables *aquellas que pueden ser directamente medidas*, sino que también incorporan variables latentes, como la “satisfacción del cliente”, el “compromiso organizacional” o la “percepción de riesgo”, conceptos abstractos que juegan un papel crucial en teorías complejas dentro de las ciencias sociales y empresariales. Estos modelos permiten al investigador explorar cómo múltiples factores latentes y observables interactúan en un sistema coherente, ofreciendo una visión integral que permite analizar varios aspectos de un fenómeno simultáneamente. Esta capacidad convierte a SEM en una herramienta indispensable para los investigadores que desean examinar fenómenos multidimensionales, estructurando sus modelos teóricos con mayor precisión y permitiendo pruebas empíricas robustas (Hair et al., 1999).

La utilidad de SEM es especialmente destacable en la investigación de fenómenos como la lealtad del cliente, el liderazgo organizacional, y la

satisfacción laboral, áreas donde la interacción de diversas variables puede afectar directamente el comportamiento y el rendimiento organizacional. A través de esta técnica, los investigadores pueden no solo identificar y evaluar relaciones entre estas variables, sino también ajustar y perfeccionar sus modelos, descartando interacciones inconsistentes y confirmando aquellas que reflejan con precisión la realidad observada. Con SEM, se facilita un análisis detallado y multifacético que integra diferentes dimensiones de un fenómeno, abordando preguntas interrelacionadas como: ¿cómo afecta la calidad del servicio la satisfacción del cliente? ¿De qué manera la satisfacción influye en la lealtad? ¿Cómo se transforma esta lealtad en recomendaciones futuras? Estas preguntas, de importancia práctica y teórica, encuentran en SEM una plataforma sólida para su exploración y respuesta.

En un contexto donde los datos y su correcta interpretación se han convertido en el pilar de decisiones empresariales y académicas, los Modelos de Ecuaciones Estructurales surgen como una metodología integral para la investigación avanzada, ofreciendo no solo respuestas sino también claridad en fenómenos interdependientes. Este texto, orientado a estudiantes de posgrado e investigadores, explora el potencial de SEM en la construcción y evaluación de modelos teóricos aplicados a problemas contemporáneos, proporcionando una base teórica y una guía práctica para su implementación en estudios que buscan no solo describir, sino entender profundamente los comportamientos y actitudes en contextos organizacionales y de mercado.

Manuel Anchapuri

**Sección 1: Introducción al Modelo de Ecuaciones
Estructurales (SEM)**

CAPITULO I

Capítulo 1: Origen y Evolución de SEM en Ciencias Empresariales y Sociales

Introducción al Modelo de Ecuaciones Estructurales (SEM)

El Modelo de Ecuaciones Estructurales (SEM, por sus siglas en inglés) es una poderosa técnica estadística que permite analizar relaciones complejas entre variables observables y latentes. En ciencias empresariales y sociales, SEM ha ganado popularidad debido a su capacidad para modelar múltiples relaciones causales y medir constructos teóricos abstractos, como la satisfacción laboral, el compromiso organizacional y el comportamiento del consumidor (Hair et al., 2019; Byrne, 2016).

Origen de SEM: Bases Teóricas y Metodológicas

Los modelos de ecuaciones estructurales surgen en el año 1921 por el genetista Sewall Green Wright, quien los implementó en la genética, con el fin de analizar un conjunto de relaciones entre una o más variables independientes, desarrollando una forma de romper las altas correlaciones observadas en un sistema de ecuaciones matemáticas que describían sus hipótesis respecto a unas relaciones causales, estas relaciones entre las variables fueron representadas en un “path diagram” (diagrama de caminos), también conocido como “Análisis Path”, un método que permite evaluar el ajuste de modelos teóricos en los que se propone un conjunto de relaciones de dependencia entre variables.

En los años 70 otros investigadores reconocieron la importancia del diagrama de caminos y comenzaron a trabajar en esta dirección, como Lawley (1940). Boudon (1965) y Duncan (1969) propusieron otra variante de análisis multivariante vinculada a los diagramas de caminos para ponderar los efectos causales. Blalock (1969) planteó que todo modelo causal se basa en una serie de supuestos y se refiere a un número limitado de variables. Se postula en ellos una relación de causa-efecto (o de causación recíproca) entre variables (independientes, dependientes), buscando mantener aislados los posibles efectos de otras variables causales.

Jöreskog (1978), desarrolló modelos de ecuaciones estructurales e incorporó las características del análisis Path (diagrama de caminos), sus logros se deben a la combinación de elementos del análisis de caminos y el análisis factorial estableciendo las relaciones de las variables. Esta conjunción de planteamientos dio lugar a lo que ahora se llama modelo de medida, que relaciona variables latentes con variables observadas en las ecuaciones estructurales, y el análisis Path, con el que se establecen las relaciones entre variables latentes, se conoce como modelo de estructura, también dedujo la base de los modelos de ecuaciones estructurales, en los que se incorpora el error de medida y las relaciones entre variables latentes.

Matemáticamente, estos modelos son más complejos de estimar que otros modelos multivariados como los de regresión o análisis factorial exploratorio y por ello su uso no se extendió hasta 1973, momento en el que apareció el programa de análisis LISREL (por sus siglas en inglés, Linear Structural Relations) (Jöreskog, 1973). El programa LISREL fue perfeccionado, dando lugar al LISREL VI (Jöreskog y Sörbom, 1986), que ofrecía una mayor variedad de métodos de estimación. El EQS (Abreviatura de Structural Equations) (Bentler, 1985) es el otro paquete utilizado tradicionalmente para este tipo de análisis. En la actualidad, existen otros programas de estimación en entorno gráfico, como el AMOS (por sus siglas en Inglés, Analysis of Moment Structures) (Arbuckle, 1997). En la

actualidad, es posible utilizar también el programa STATA y el programa R para estimar estos modelos (Stata Corp., 2013) y (R Core Team, 2017).

También existe Jamovi que se fundó para desarrollar una plataforma estadística abierta y gratuita que sea intuitiva de usar y pueda proporcionar los últimos desarrollos en metodología estadística. En el centro de la filosofía jamovi, es que el software científico debe ser “community driven”, donde cualquiera puede desarrollar y publicar análisis, y ponerlos a disposición de una amplia audiencia.

Jamovi pretende ser una plataforma neutral, y no toma ninguna posición con respecto a las filosofías estadísticas en competencia. El proyecto no fue fundado para promover una ideología estadística particular, sino para servir como un espacio seguro donde se pudieran publicar diferentes enfoques estadísticos uno al lado del otro, y se consideran miembros de primer nivel de la comunidad jamovi.

Desde hace algunos años, también mencionado en Hair y cols. (1999), los modelos de ecuaciones estructurales se han utilizado en casi todos los campos de estudio concebibles, incluyendo la educación, el marketing, la psicología, la sociología, la salud, la demografía, el comportamiento organizacional, la biología e incluso la genética. Las razones de su atractivo para áreas tan diversas son dobles:

- Proporciona un método directo de tratar con múltiples relaciones simultáneamente a la vez que se da eficiencia estadística,
- Es notable la capacidad para evaluar las relaciones exhaustivamente y proporcionar una transición desde el análisis exploratorio al confirmatorio.

SEM tiene sus raíces en varias disciplinas estadísticas y psicométricas, en especial en el análisis de variables latentes y el Análisis Factorial Confirmatorio (AFC). En la década de 1960,

investigadores como Jöreskog y Sörbom comenzaron a explorar cómo el análisis factorial podía integrarse con los modelos de regresión lineal para crear un marco unificado que permitiera estudiar simultáneamente variables observadas y latentes (Kline, 2016). Estos primeros desarrollos fueron fundamentales para el progreso del SEM, que desde entonces se ha basado en técnicas como el **Análisis Factorial Exploratorio (AFE)**, modelos de regresión y el método de mínimos cuadrados parciales (PLS).

Jöreskog (1970) fue pionero en el campo al proponer el uso del análisis factorial confirmatorio para validar la estructura de los constructos teóricos en modelos sociales y empresariales. Su trabajo ayudó a consolidar SEM como una metodología integral para probar teorías de múltiples variables en un solo modelo. Además, en la década de 1980, la inclusión del software LISREL impulsó el uso de SEM, facilitando el desarrollo de modelos más complejos en investigaciones empíricas (Kaplan, 2008).

Evolución de SEM: Integración en Ciencias Empresariales y Sociales

A medida que SEM avanzaba, se convirtió en una herramienta esencial en ciencias empresariales y sociales. En marketing, por ejemplo, SEM ha sido crucial para modelar el comportamiento del consumidor, el valor de marca y la lealtad de los clientes. Hair et al. (2019) destacan cómo el análisis SEM permite a los investigadores capturar relaciones no lineales y efectos indirectos en estudios de satisfacción del cliente, lo que proporciona una comprensión más profunda del comportamiento del consumidor.

En recursos humanos, SEM se ha utilizado para estudiar constructos complejos como el compromiso organizacional y el clima laboral. Los estudios sobre el modelo de liderazgo

transformacional y su impacto en el desempeño laboral han mostrado cómo SEM permite analizar múltiples dimensiones y relacionar variables mediadoras, tales como la motivación y el compromiso (Avolio & Yammarino, 2013). Byrne (2016) menciona que el enfoque de SEM ha permitido avanzar en la medición precisa de estos constructos, lo que es esencial en campos como la gestión del talento.

Ejemplo Aplicado en Marketing

Un estudio en el contexto latinoamericano de investigación empresarial puede observarse en el análisis de factores que influyen en la lealtad del cliente en el sector minorista en México y Colombia. Utilizando SEM, Torres et al. (2021) demostraron cómo el modelo permite identificar factores mediadores como la percepción de valor y satisfacción, que afectan indirectamente la lealtad del cliente. Este tipo de análisis no podría llevarse a cabo con técnicas estadísticas convencionales, ya que las relaciones indirectas y mediadoras son complejas y requieren el modelado simultáneo de varias variables.

“La relación entre la calidad en el servicio, satisfacción del cliente y lealtad del cliente: un estudio de caso de una empresa comercial en México”

Disponible <https://doi.org/10.29059/cienciauat.v15i2.1369>

Avances Tecnológicos y SEM en la Era Digital

Con el avance de la tecnología y el desarrollo de software especializado, como AMOS, Mplus y paquetes en R, SEM se ha vuelto más accesible para investigadores de todo el mundo. Hair et al. (2019) señalan que los avances en los programas de software han permitido a los investigadores de ciencias empresariales y sociales

implementar modelos complejos sin necesidad de habilidades avanzadas en programación.

La accesibilidad y facilidad de uso de estos programas han promovido el crecimiento de SEM en diversas disciplinas, incluidas las ciencias sociales en América Latina. Estudios recientes han empleado SEM para evaluar el impacto de políticas públicas, como en el análisis de programas de inclusión social en Perú, donde se ha utilizado SEM para modelar el impacto de políticas de empleo en la satisfacción y percepción de bienestar de los beneficiarios (López & Morales, 2022).

SEM en Ciencias Sociales: Perspectivas y Aplicaciones en Latinoamérica

En ciencias sociales, SEM ha permitido el análisis de fenómenos complejos como la cohesión social, la percepción de inseguridad y el bienestar. Kline (2016) destaca que, en contextos socioculturales heterogéneos, como los de América Latina, SEM es particularmente útil para modelar y validar constructos relacionados con el capital social y la percepción de justicia. Por ejemplo, en un estudio sobre cohesión social en comunidades urbanas en Chile y Argentina, Pérez y González (2020) utilizaron SEM para analizar cómo la percepción de justicia y el sentido de pertenencia impactan el bienestar subjetivo.

La Importancia de SEM en la Investigación Actual

SEM ha evolucionado hasta convertirse en una herramienta indispensable en la investigación cuantitativa, especialmente en ciencias empresariales y sociales. Sus capacidades permiten a los investigadores abordar preguntas complejas, probar teorías y validar constructos en contextos donde las relaciones entre variables no son directamente observables (Byrne, 2016). Esta flexibilidad y

profundidad analítica han hecho que SEM sea altamente valorado en estudios académicos y de consultoría, consolidándolo como una metodología clave en la toma de decisiones informadas en el contexto latinoamericano y global.

CAPITULO II

Capítulo 2: Importancia de SEM en Ciencias Empresariales y Sociales

Introducción a la Importancia de SEM en Investigación Científica

El Modelo de Ecuaciones Estructurales (SEM) ha revolucionado la forma en que se realiza la investigación científica en campos como las ciencias empresariales y sociales. Su capacidad para modelar relaciones complejas entre variables observadas y latentes lo convierte en una herramienta esencial para analizar constructos abstractos y fenómenos sociales de manera rigurosa y precisa. En este capítulo, se aborda la importancia de SEM en estos campos de estudio, con ejemplos aplicados y casos prácticos en América Latina, destacando su utilidad en la toma de decisiones, la formulación de políticas y la mejora de prácticas organizacionales (Hair et al., 2019; Byrne, 2016).

SEM en Ciencias Empresariales: Aplicaciones y Relevancia

En ciencias empresariales, SEM se ha vuelto indispensable para el estudio de relaciones que impactan directamente la competitividad y el desempeño organizacional. Por ejemplo, en el área de marketing, SEM permite analizar el comportamiento del consumidor y modelar la lealtad de marca, la satisfacción del cliente y el valor percibido de los productos (Hair et al., 2019). En un estudio realizado en el sector minorista de México y Colombia, Torres et al. (2021) utilizaron SEM para identificar factores que

influyen en la lealtad de los clientes, descubriendo que la satisfacción del cliente actúa como mediador entre la percepción de valor y la lealtad. Este tipo de análisis permite a las empresas formular estrategias de marketing más efectivas y personalizadas.

Otro ejemplo en el ámbito empresarial es el análisis del compromiso organizacional. SEM permite a los investigadores analizar la influencia de variables como el estilo de liderazgo, la motivación intrínseca y el clima organizacional en el compromiso de los empleados y, a su vez, su impacto en el desempeño (Avolio & Yammarino, 2013). En Perú, una investigación en una empresa minera usó SEM para analizar cómo el liderazgo transformacional afectaba el compromiso y el desempeño de los empleados. Los resultados demostraron que el liderazgo transformacional impacta indirectamente el desempeño laboral a través de la satisfacción y motivación, lo cual permitió a la empresa ajustar sus programas de desarrollo de liderazgo para maximizar el compromiso organizacional (López & Morales, 2022).

SEM en Ciencias Sociales: Aplicaciones en el Contexto Latinoamericano

En ciencias sociales, SEM ha sido clave para abordar temas complejos y multifactoriales como la inclusión social, la cohesión comunitaria y la percepción de seguridad. En un estudio sobre la cohesión social en comunidades urbanas de Argentina y Chile, Pérez y González (2020) emplearon SEM para modelar la influencia de la percepción de justicia y el sentido de pertenencia en el bienestar subjetivo de los ciudadanos. Este estudio subrayó cómo el sentido de pertenencia y la percepción de equidad impactan significativamente el bienestar de las comunidades urbanas, proporcionando una base sólida para el diseño de políticas públicas orientadas a mejorar la cohesión social.

Otra área en la que SEM ha demostrado su utilidad es en el análisis de programas de políticas públicas en América Latina. En Perú, López y Morales (2022) utilizaron SEM para evaluar el impacto de un programa gubernamental de inclusión social sobre la satisfacción de los beneficiarios en comunidades rurales. Los resultados mostraron que la percepción de transparencia y eficiencia en la administración del programa tenía un efecto positivo significativo en la satisfacción de los beneficiarios. Esta información fue fundamental para realizar ajustes en la implementación del programa y mejorar la percepción y el impacto de este en las comunidades rurales.

Casos Prácticos de SEM en Ciencias Empresariales y Sociales

Caso 1: Lealtad de Cliente en el Sector Minorista en México y Colombia

La lealtad del cliente es un factor determinante para la sostenibilidad de las empresas, especialmente en sectores altamente competitivos como el minorista. Torres et al. (2021) aplicaron SEM en una investigación para analizar los factores que influyen en la lealtad del cliente en supermercados de México y Colombia. El modelo permitió identificar relaciones directas e indirectas entre la percepción de valor, la satisfacción y la lealtad, revelando que la satisfacción del cliente actúa como un mediador esencial. Estos hallazgos han permitido a las empresas formular estrategias de fidelización más precisas, dirigidas a mejorar la experiencia del cliente y su satisfacción general, lo que finalmente impacta positivamente en su lealtad a la marca.

Caso 2: Liderazgo y Compromiso Organizacional en Empresas Mineras en Perú

En el ámbito de la gestión de recursos humanos, SEM ha sido crucial para entender cómo el estilo de liderazgo impacta en el compromiso y desempeño de los empleados. López y Morales (2022) llevaron a cabo un estudio en una empresa minera peruana, utilizando SEM para modelar el efecto del liderazgo transformacional en el compromiso organizacional y el desempeño laboral. Los resultados mostraron que el liderazgo transformacional no solo afecta directamente el desempeño, sino que también lo hace indirectamente a través de la motivación y el compromiso de los empleados. Esta información ha sido utilizada para implementar programas de desarrollo de liderazgo adaptados, mejorando así el clima organizacional y optimizando los resultados de la empresa.

Caso 3: Cohesión Social en Comunidades Urbanas de Argentina y Chile

En el campo de las ciencias sociales, SEM ha permitido estudiar constructos abstractos como la cohesión social y el bienestar comunitario. Pérez y González (2020) utilizaron SEM para investigar la relación entre la percepción de justicia y el sentido de pertenencia con el bienestar subjetivo en comunidades urbanas. El análisis mostró que la percepción de justicia impacta significativamente el sentido de pertenencia y, en última instancia, el bienestar de los ciudadanos. Estos hallazgos proporcionan una base empírica para diseñar intervenciones y políticas públicas destinadas a mejorar la cohesión social y el bienestar de las comunidades urbanas.

El Valor de SEM para la Investigación en Ciencias Empresariales y Sociales

SEM permite a los investigadores en ciencias empresariales y sociales realizar análisis detallados y comprender mejor las relaciones complejas entre variables. Al permitir la integración de múltiples constructos y relaciones mediadoras y moderadoras en un solo modelo, SEM se ha establecido como una metodología robusta y flexible que responde a las demandas de investigaciones avanzadas en contextos dinámicos y multifactoriales (Byrne, 2016). La capacidad de SEM para abordar fenómenos complejos ha hecho que esta técnica sea cada vez más popular en América Latina, especialmente en el análisis de políticas públicas, gestión empresarial y estudios de bienestar social.

Gracias a SEM, investigadores y profesionales pueden formular conclusiones basadas en datos rigurosos que apoyan el diseño de estrategias empresariales efectivas y la implementación de políticas públicas bien fundamentadas, promoviendo así el desarrollo económico y social en el contexto latinoamericano.

El Modelo de Ecuaciones Estructurales (SEM)

El Modelo de Ecuaciones Estructurales (SEM) es una técnica estadística esencial en las investigaciones científicas de las ciencias empresariales y sociales debido a su capacidad para modelar y analizar relaciones complejas entre variables observadas y latentes. Este método integra análisis factorial confirmatorio y modelos de regresión múltiple, lo que permite evaluar simultáneamente relaciones de dependencia directa e indirecta en modelos teóricos amplios (Sun & Chen, 2024; García-González & Ruíz, 2022).

En el ámbito empresarial, SEM permite a los investigadores explorar constructos abstractos como la satisfacción del cliente, el compromiso organizacional y la adopción de nuevas tecnologías, elementos fundamentales en estudios de marketing, gestión de recursos humanos y comportamiento organizacional. Por ejemplo, en el análisis del comportamiento del consumidor, SEM puede explicar cómo factores como la percepción de marca y la calidad del servicio influyen en la intención de recompra, mediada por la satisfacción del cliente (Yi & Chen, 2024). Además, su aplicación en la gestión de recursos humanos permite comprender las interacciones entre liderazgo, clima organizacional y desempeño, proporcionando una visión integral de cómo estos factores interactúan en el entorno laboral (García-González et al., 2022).

En las ciencias sociales, SEM facilita el estudio de fenómenos como la cohesión social y la percepción de seguridad, que son multifacéticos y están influenciados por factores contextuales y psicológicos. La versatilidad de SEM para integrar variables formativas y reflectivas en un solo modelo ofrece un marco robusto para validar modelos explicativos, lo cual fortalece la rigurosidad y aplicabilidad de los estudios en este campo (MDPI, 2024). Esta capacidad es crucial para realizar investigaciones con mayor precisión, dado que permite la inclusión de variables latentes difíciles de medir directamente, aportando mayor profundidad en la comprensión de procesos sociales complejos.

SEM es una herramienta poderosa para la investigación científica que brinda a los investigadores en ciencias empresariales y sociales un enfoque integral y robusto para modelar relaciones complejas y evaluar teorías de alto nivel. Su capacidad para combinar análisis estadísticos avanzados en un único modelo convierte a SEM en una metodología indispensable en la

investigación empírica moderna (Sun & Chen, 2024; García-González & Ruíz, 2022).

Principales Componentes de SEM

El Modelo de Ecuaciones Estructurales (SEM) se compone de varios elementos fundamentales que permiten a los investigadores modelar relaciones complejas entre variables latentes y observadas. A continuación, se detallan los principales componentes de SEM y se ofrecen ejemplos específicos en el contexto de ciencias empresariales y sociales para ilustrar su aplicación.

1. Variables Latentes

Las **variables latentes** representan conceptos abstractos que no se pueden medir directamente, como el liderazgo, la satisfacción del cliente, o el clima organizacional en el ámbito empresarial. En ciencias sociales, variables como la cohesión social o la percepción de justicia también son ejemplos de constructos latentes. Las variables latentes se estiman a través de múltiples **variables observadas** o indicadores que reflejan aspectos de estos constructos.

Ejemplo en ciencias empresariales: La satisfacción del cliente, un constructo clave en marketing, puede medirse mediante variables observadas como la “calidad percibida del producto”, “servicio al cliente” y “experiencia de compra” (Yi & Chen, 2024). En este caso, la satisfacción del cliente es la variable latente que representa un fenómeno no directamente observable, mientras que sus indicadores ofrecen medidas indirectas de esta satisfacción.

Ejemplo en ciencias sociales: En el estudio de la cohesión social, la variable latente “confianza en la comunidad” podría ser medida a través de indicadores como “nivel de interacción con vecinos” y “participación en eventos comunitarios” (Sun & Chen, 2024) y demás indicadores.

2. Variables Observadas (Indicadores)

Las **variables observadas** son los indicadores que permiten medir las variables latentes. Estas variables son directamente cuantificables y reflejan distintos aspectos de un mismo constructo. En SEM, las variables observadas pueden ser reflejadas (indicadores que dependen del constructo latente) o formativas (indicadores que forman el constructo).

Ejemplo en ciencias empresariales: En un estudio de compromiso organizacional, los indicadores podrían incluir la “satisfacción con las políticas de la empresa”, “interacción con colegas” y “disposición a realizar esfuerzos adicionales” (García-González & Ruíz, 2022) y otros indicadores.

Ejemplo en ciencias sociales: Para medir la variable latente “bienestar social”, los indicadores observados podrían incluir “satisfacción con la calidad de los servicios públicos” y “percepción de seguridad” (MDPI, 2024) y demás.

3. Modelo de Medición

El **modelo de medición** especifica cómo las variables observadas reflejan a las variables latentes, y generalmente se evalúa mediante análisis factorial confirmatorio (AFC) para validar estas relaciones. Este modelo es esencial para verificar que los indicadores seleccionados representen adecuadamente los constructos latentes propuestos en la investigación.

Ejemplo en ciencias empresariales: En la medición de “engagement” o *compromiso de los empleados*, el modelo de medición especificaría cómo indicadores como “motivación en el trabajo” y “satisfacción en el puesto” se relacionan con el constructo de compromiso, permitiendo validar su consistencia y validez (Yi & Chen, 2024).

Ejemplo en ciencias sociales: Para la variable latente “bienestar psicológico”, los indicadores podrían incluir “autoestima” y “sentido de propósito”, y el modelo de medición se encargaría de confirmar que estos indicadores reflejan efectivamente el bienestar psicológico de los individuos (Sun & Chen, 2024).

4. Modelo Estructural

El **modelo estructural** especifica las relaciones causales y de dependencia entre las variables latentes. A través de ecuaciones simultáneas, el modelo estructural permite investigar cómo un constructo puede predecir o influir en otro dentro de un marco teórico, facilitando la comprensión de relaciones complejas de causalidad y mediación.

Ejemplo en ciencias empresariales: En un modelo que analiza los factores de lealtad del cliente, el modelo estructural podría especificar que la “satisfacción del cliente” predice la “lealtad a la marca”, mientras que la “calidad del servicio” actúa como una variable mediadora entre ambas. Este tipo de análisis permite entender las relaciones directas e indirectas entre variables latentes en estudios de marketing (García-González & Ruíz, 2022).

Ejemplo en ciencias sociales: En un modelo de cohesión social, el modelo estructural podría representar cómo “confianza en las instituciones” predice “participación comunitaria”, y cómo “sentido de pertenencia” mediaría esta relación, facilitando un análisis detallado del impacto de las instituciones en la participación social (MDPI, 2024).

Figura 1

Diagrama SEM: Lealtad del cliente y la satisfacción del cliente

SEM Example in Business Science: Customer Satisfaction and Brand Loyalty

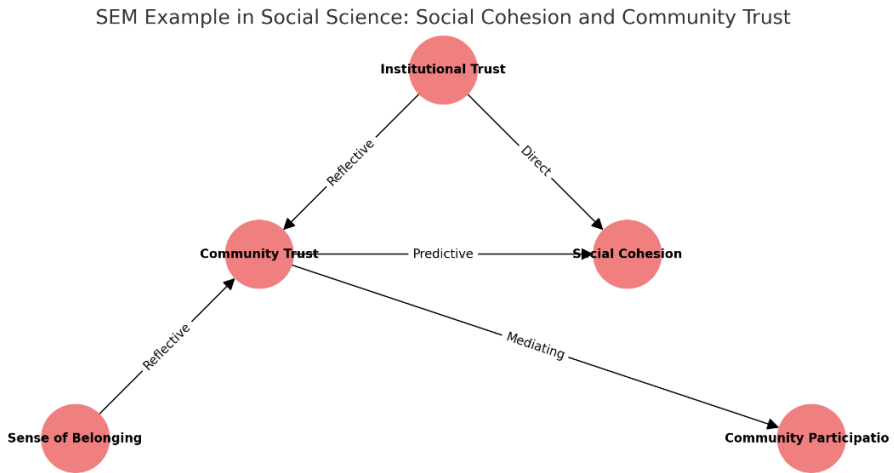


Modelo de Ecuaciones Estructurales (SEM) en ciencias empresariales, Análisis de la lealtad del cliente y la satisfacción del cliente. En este modelo:

- **Variables Latentes:** La **Satisfacción del Cliente** y la **Lealtad a la Marca** son variables latentes representadas mediante indicadores como la calidad del servicio y la intención de compra.
- **Relaciones Estructurales:** La calidad del servicio y la calidad del producto influyen en la satisfacción del cliente. Esta, a su vez, actúa como mediadora hacia la intención de compra y la lealtad a la marca.

Figura 2

Diagrama SEM: cohesión social y la confianza comunitaria



Este es un diagrama del Modelo de Ecuaciones Estructurales (SEM) aplicado en ciencias sociales, enfocado en la cohesión social y la confianza comunitaria. En este modelo:

- **Variables Latentes:** La **Confianza Comunitaria** y la **Cohesión Social** son variables latentes que se miden a través de indicadores como la confianza institucional y el sentido de pertenencia.
- **Relaciones Estructurales:** La confianza en las instituciones y el sentido de pertenencia influyen en la confianza comunitaria, la cual a su vez media la relación con la participación comunitaria y la cohesión social.

Ambos diagramas ilustran cómo SEM permite modelar relaciones complejas entre constructos latentes en distintos contextos de investigación.

Metodología SEM

La metodología de Modelos de Ecuaciones Estructurales (SEM) ha ganado relevancia en las ciencias del comportamiento debido a su capacidad para analizar constructos teóricos que no pueden observarse directamente. Los investigadores suelen trabajar con variables latentes o factores no medibles, que representan conceptos abstractos como "satisfacción del cliente" o "percepción del riesgo". Estas variables latentes, al no ser directamente observables, requieren ser operacionalizadas a través de variables observables (también llamadas indicadores o variables manifiestas), que actúan como "proxy" y permiten medirlas de manera indirecta (Byrne, 2010).

De manera similar a la metodología Box-Jenkins utilizada en econometría, SEM sigue una serie de etapas bien definidas (Batista Foguet & Coenders Gallart, 2000):

1. **Especificación:** A partir de la teoría existente, el investigador define las relaciones entre las variables relevantes, estableciendo qué factores están relacionados entre sí y en qué dirección. Por ejemplo, en un estudio sobre satisfacción laboral, se podría modelar cómo factores como el ambiente de trabajo y el liderazgo afectan la motivación y el rendimiento.
2. **Identificación:** En esta etapa se evalúa si la información proporcionada por las variables observables es suficiente para estimar los parámetros del modelo. Sin una identificación adecuada, el modelo no será capaz de proporcionar resultados precisos o interpretables.
3. **Recogida de datos:** Aquí se recopila la información empírica necesaria, verificando que los datos cumplan con los supuestos del modelo, como la normalidad multivariante y la ausencia de valores atípicos.

4. **Estimación:** A través de algoritmos de optimización, se estiman los parámetros que minimizan la discrepancia entre la matriz de covarianzas observada y la matriz implícita en el modelo teórico. Por ejemplo, se podría estimar cómo cada indicador observable contribuye a la satisfacción laboral.
5. **Evaluación:** Se analiza la bondad del ajuste del modelo para determinar si los datos respaldan la estructura teórica planteada. Esto implica comparar la matriz de covarianzas estimada con la matriz observada para evaluar si el modelo refleja adecuadamente las relaciones entre las variables.
6. **Utilización del modelo:** Una vez validado, el modelo puede utilizarse para validar teorías o comparar diferentes modelos. Esto permite al investigador explorar cómo cambios en una variable pueden afectar a otras, facilitando la toma de decisiones basadas en evidencia.

Diagnóstico del ajuste del modelo

Antes de aplicar el modelo para medir la intensidad de las relaciones entre variables, es crucial realizar un diagnóstico del ajuste. Para considerar un modelo como adecuado, deben analizarse los siguientes aspectos:

- **Bondad de ajuste:** Evalúa qué tan bien el modelo representa los datos empíricos tanto de forma global como parcial. A nivel global, se observa si el modelo general es apropiado, mientras que a nivel parcial se identifican parámetros específicos que podrían no ajustarse bien, permitiendo al investigador ajustar y refinar el modelo.
- **Parsimonia:** Entre modelos que explican de forma similar, se prefiere el que utiliza menos parámetros, ya que un modelo más simple suele ser más generalizable y práctico.

- **Comparación de modelos:** Si existen modelos alternativos, se compara el modelo propuesto con otros para seleccionar el que mejor explique los datos.
- **Consistencia teórica:** Es importante que los signos de los coeficientes y la dirección de las relaciones coincidan con la teoría, de modo que el modelo refleje los conceptos teóricos subyacentes.

Diagrama de Senderos (Path Diagram)

El Diagrama de Senderos (Path Diagram) es una representación gráfica que ilustra las relaciones entre las variables latentes y sus indicadores observables mediante grafos. Según las convenciones establecidas (Batista Foguet & Coenders Gallart, 2000):

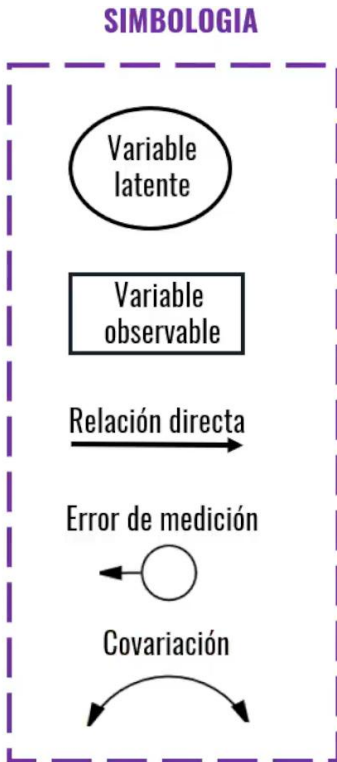
1. **Relaciones causales:** Se representan con flechas unidireccionales que apuntan de la causa al efecto, indicando el impacto de una variable sobre otra. Por ejemplo, una flecha desde "satisfacción laboral" hacia "rendimiento" implica que la primera afecta la segunda.
2. **Variables latentes y observables:** Las variables latentes se dibujan en elipses y las observables en rectángulos. Las perturbaciones, análogas a los errores de la regresión, se representan en círculos, ya que también son variables latentes.
3. **Covariación:** Se indica con flechas bidireccionales entre dos variables, representando una relación simétrica o correlación entre ellas.

La metodología SEM es una herramienta integral y versátil que permite analizar constructos complejos y sus relaciones, proporcionando una comprensión profunda de los fenómenos investigados. Ya sea en estudios de satisfacción laboral, efectividad organizacional o

comportamiento del consumidor, SEM ofrece un marco robusto para validar teorías y obtener insights accionables en áreas diversas.

Figura 3

Simbología SEM



Sección 2: Principales Componentes de SEM

CAPITULO III

Capítulo 3: Variables Latentes y Observadas

El Modelado de Ecuaciones Estructurales (SEM) permite analizar las relaciones entre variables observadas (medidas directamente) y variables latentes (constructos no observables que se infieren a partir de las variables observadas). Este enfoque es crucial en ciencias empresariales y sociales, donde conceptos abstractos como la satisfacción del cliente, el compromiso laboral o la lealtad se deben medir de manera precisa para obtener conclusiones válidas. Este capítulo explora la clasificación y los métodos para identificar y medir constructos latentes, presentando un caso de estudio detallado sobre la satisfacción del cliente en el sector bancario en Colombia.

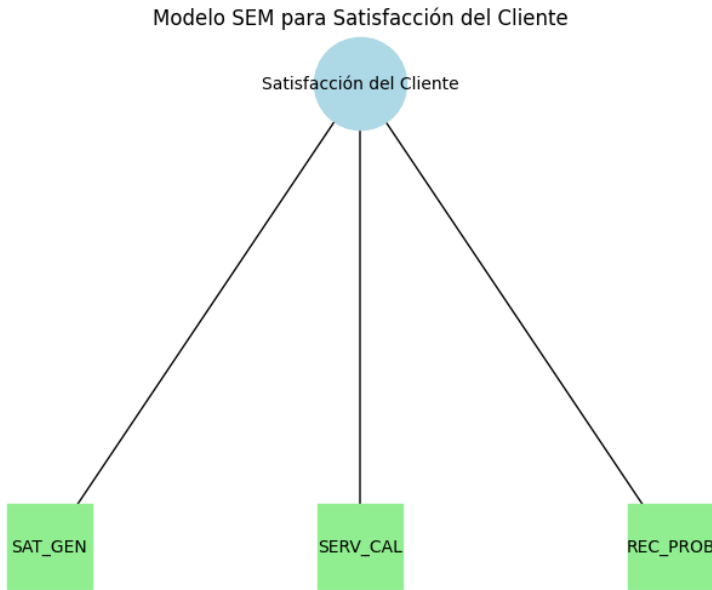
Clasificación de Variables en SEM

En SEM, es fundamental distinguir entre los diferentes tipos de variables involucradas en el modelo:

1. **Variables Observadas:** Son las variables que se miden directamente a través de encuestas, cuestionarios o registros. En el caso de satisfacción del cliente, pueden incluir preguntas directas sobre satisfacción general, calidad de servicio y probabilidad de recomendar el banco.
2. **Variables Latentes:** Estas representan conceptos no observables directamente, como la satisfacción del cliente. En SEM, las variables latentes se miden a través de indicadores observados (variables observadas) que se asocian fuertemente con el constructo.

Figura 4

Modelo SEM: satisfacción del cliente



En este caso, la **variable latente** será la satisfacción del cliente, que es un concepto abstracto y no observable directamente. Para medirlo, podemos utilizar tres **variables observadas** que se recolectan mediante encuestas o cuestionarios:

1. **Satisfacción General (SAT_GEN)**: una pregunta que mide la satisfacción general del cliente con el banco, como "¿Qué tan satisfecho está en general con los servicios del banco?" mediante una escala de Likert
2. **Calidad de Servicio (SERV_CAL)**: una pregunta que mide la percepción de calidad del servicio, como "¿Qué tan buena considera la calidad de los servicios ofrecidos por el banco?"

3. **Probabilidad de Recomendación (REC_PROB)**: una pregunta sobre la intención de recomendar el banco, como "¿Qué tan probable es que recomiende el banco a un amigo o familiar?".

Para desarrollar la medición de actitudes, percepciones y comportamientos en investigación social y empresarial, es común utilizar diferentes escalas psicométricas. La **escala de Likert** y el **diferencial semántico** son de las más utilizadas, pero también existen otras escalas importantes que ofrecen ventajas según el tipo de variable y el nivel de precisión requerido.

- a. **Escala de Likert**: Es una de las escalas más comunes en ciencias sociales y empresariales, que permite medir la intensidad de las actitudes en una serie de afirmaciones. Esta escala generalmente incluye opciones que van desde "totalmente en desacuerdo" hasta "totalmente de acuerdo". Es útil para medir actitudes y percepciones en una dimensión, como la satisfacción o la motivación del empleado en un contexto empresarial (Likert, 1932).
- b. **Diferencial Semántico**: Creada por Charles E. Osgood, esta escala mide connotaciones de palabras o conceptos en un continuo entre adjetivos opuestos, como "bueno-malo" o "útil-inútil". Es especialmente útil para evaluar percepciones y valoraciones subjetivas de productos o servicios, ya que permite obtener un perfil actitudinal del objeto evaluado a través de distintos adjetivos (Osgood, Suci, & Tannenbaum, 1957).
- c. **Escala Guttman**: Esta escala se utiliza para medir actitudes que pueden ordenarse de menor a mayor intensidad, formando una jerarquía lógica. Cada reactivo implica un nivel mayor de acuerdo o aceptación, y se asume que, si una persona está de acuerdo con una afirmación intensa, también estará de acuerdo con las afirmaciones menos intensas. Es aplicable en estudios de opiniones firmes o prejuicios.

- d. **Escala de Stapel:** Similar al diferencial semántico, pero utiliza una escala unipolar con puntos tanto positivos como negativos alrededor de un atributo central. Por ejemplo, en lugar de "bueno-malo," se puede tener una sola palabra en el centro (e.g., "satisfactorio"), y el encuestado indicará el grado de satisfacción en torno a esta palabra. Es ideal para medir actitudes hacia atributos específicos de productos.
- e. **Escala de Ordenación por Rangos (Ranking):** Aquí, a los participantes se les solicita clasificar una serie de opciones en orden de preferencia. Es útil para comparar preferencias entre opciones de productos o servicios, permitiendo identificar cuáles son percibidos como más o menos importantes por el consumidor en estudios de marketing.
- f. **Escala de Sumativa Thurstone:** Aunque menos común hoy en día debido a su complejidad, esta escala se basa en una serie de afirmaciones con puntajes preestablecidos para cada afirmación. Se utiliza cuando es necesario medir actitudes con un nivel de precisión alto, pero requiere análisis estadísticos avanzados para su diseño y es costosa de implementar.
- g. **Escala Visual Análoga (VAS):** Es una escala continua, donde los encuestados indican un punto en una línea que representa un rango, como "nada satisfecho" a "totalmente satisfecho". Esta escala es útil para medir experiencias subjetivas y ofrece más sensibilidad al permitir la selección en una línea continua.
- h. **Escala de Intervalos Iguales:** En esta escala, se presentan categorías de respuesta con igual distancia entre sí, permitiendo así un análisis más preciso, especialmente útil en estudios donde se desea medir intervalos de opinión o niveles de intensidad de manera uniforme. Un ejemplo es medir la frecuencia de uso de un servicio,

con opciones como “Nunca”, “Rara vez”, “A veces”, “Frecuentemente”.

Para nuestro ejemplo:

- **Variable Latente:** Satisfacción del Cliente
 - Representado por un círculo en el diagrama SEM.
 - **Variables Observadas:** SAT_GEN, SERV_CAL, REC_PROB
 - Representadas por rectángulos en el diagrama.
 - **Relaciones entre Variables:**
 - La variable latente "Satisfacción del Cliente" (en el círculo) se conecta con cada una de las variables observadas (en los rectángulos) mediante flechas unidireccionales que representan cómo estas variables observadas miden el constructo latente.
3. **Variables Exógenas y Endógenas:**
- **Variables Exógenas:** Actúan como variables independientes y no son afectadas por otras variables en el modelo.
 - **Variables Endógenas:** Son dependientes y están influenciadas por otras variables (ya sean observadas o latentes).

Identificación y Medición de Constructos Latentes

Para medir constructos latentes como la satisfacción del cliente, es importante construir un conjunto de indicadores fiables y válidos. Los métodos más comunes para identificar y medir estos constructos son:

- **Análisis Factorial Exploratorio (AFE):** Se utiliza para identificar la estructura subyacente en los datos y descubrir cuáles variables observadas están más asociadas con ciertos factores o constructos.
- **Análisis Factorial Confirmatorio (AFC):** Confirma la estructura del modelo identificada en AFE o en base a una hipótesis teórica y valida la relación entre las variables observadas y los constructos latentes.

Para ilustrar estos métodos, presentaremos un caso de estudio sobre la medición de satisfacción del cliente en el sector bancario de Colombia.

Importancia de los Coeficientes de Asimetría y Curtosis en el Análisis de Normalidad y el análisis SEM

En el análisis estadístico, los coeficientes de asimetría y curtosis son fundamentales para evaluar si los datos siguen una distribución normal, lo cual es un supuesto clave en muchos métodos estadísticos, incluyendo los Modelos de Ecuaciones Estructurales (SEM). Según George y Mallery (2013), los valores de asimetría y curtosis deben oscilar entre -2 y 2 para considerar que los datos no presentan desviaciones severas de la normalidad. Este rango asegura que los datos son aptos para métodos basados en máxima verosimilitud y otros procedimientos sensibles a la normalidad.

Asimetría y Curtosis: Definiciones y Aplicaciones

1. **Asimetría:** Mide la simetría de la distribución de los datos. Un valor cercano a 0 indica que los datos están distribuidos simétricamente alrededor de la media. Valores positivos indican asimetría a la derecha, mientras que valores negativos reflejan asimetría a la izquierda (George & Mallery, 2013).

Figura 5


Asimetría



2. **Curtosis:** Evalúa la "agudeza" de la distribución en comparación con una distribución normal. Valores positivos indican una distribución más apuntada (leptocúrtica), y valores negativos reflejan una distribución más plana (platicúrtica).

Figura 6

Curtosis



Importancia de los Rangos de -2 a 2

Cuando los coeficientes de asimetría y curtosis están fuera del rango de -2 a 2, se corre el riesgo de que los supuestos de normalidad no se cumplan, lo que puede invalidar las inferencias

estadísticas y sesgar los resultados de análisis como el SEM (Kline, 2021). Datos extremos o distribuciones no normales pueden:

- Influir en los estimadores de máxima verosimilitud.
- Aumentar los errores estándar.
- Reducir la precisión de las relaciones entre variables latentes y observadas.

Figura 7

SPSS Calculo de la Asimetría y la Curtosis

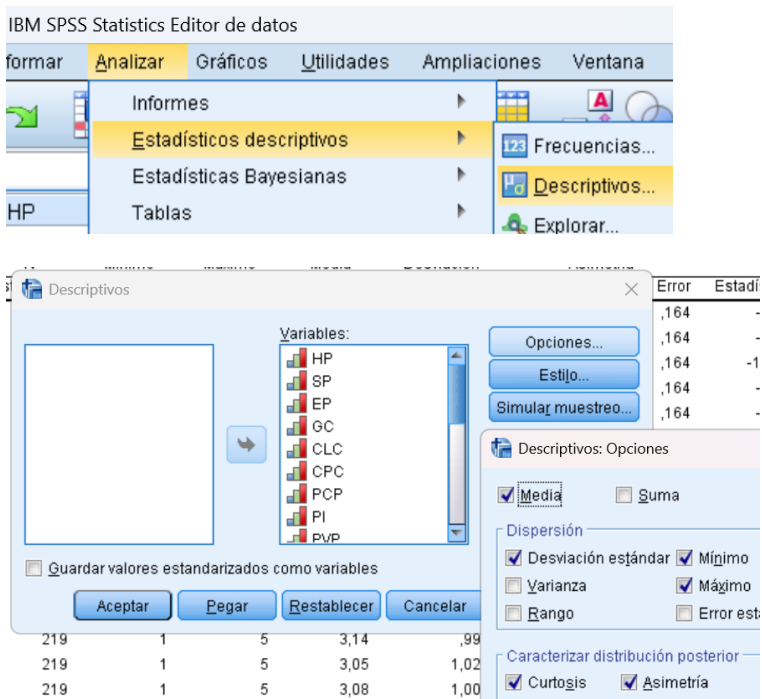


Figura 8

SPSS: Resultado de la Asimetría y la Curtosis

	Estadísticos descriptivos				
	N	Asimetría		Curtosis	
	Estadístico	Estadístico	Desv. Error	Estadístico	Desv. Error
HP	219	,624	,164	-,696	,327
SP	219	,501	,164	-,837	,327
EP	219	,323	,164	-1,115	,327
GC	219	-,425	,164	-,774	,327
CLC	219	-,565	,164	-,103	,327
CPC	219	-,666	,164	-,108	,327
PCP	219	-,112	,164	-,742	,327
PI	219	-,168	,164	-,717	,327
PVP	219	-,278	,164	-,619	,327
GPV	219	-,110	,164	-1,042	,327

Ejemplo Práctico

Un investigador está evaluando la satisfacción laboral en una muestra de empleados utilizando un cuestionario con una escala Likert de 5 puntos. Antes de proceder con un SEM, analiza la asimetría y curtosis de las respuestas.

1. Para el ítem *"Estoy satisfecho con mi salario"*, obtiene una asimetría de -1.2 y una curtosis de 0.8. Ambos valores están dentro del rango aceptable, indicando una distribución adecuada.
2. Sin embargo, para el ítem *"Estoy dispuesto a recomendar mi lugar de trabajo"*, encuentra una asimetría de -3.5 y una curtosis de 7.2, lo que indica datos altamente sesgados y con colas largas.

En este caso, el investigador debe transformar los datos o aplicar técnicas estadísticas robustas como estimadores de mínimos cuadrados ponderados para manejar la falta de normalidad.

Normalidad y Métodos Estadísticos

La normalidad de los datos es especialmente importante en procedimientos como:

- **Análisis Factorial Confirmatorio (AFC):** La falta de normalidad puede distorsionar los indicadores de bondad de ajuste (Schumacker & Lomax, 2022).
- **Pruebas de Hipótesis:** Los resultados pueden ser menos fiables si los datos no son normales, especialmente en muestras pequeñas (Tabachnick & Fidell, 2019).

Soluciones a la Falta de Normalidad

1. **Transformación de Datos:** Aplicar logaritmos, raíces cuadradas o transformaciones inversas puede mejorar la normalidad.
2. **Métodos Robustos:** Utilizar estimadores menos sensibles a la normalidad, como mínimos cuadrados ponderados (WLSMV), es común en SEM cuando la normalidad no se cumple.

Los coeficientes de asimetría y curtosis dentro del rango de -2 a 2, como sugieren George y Mallery (2013), son esenciales para asegurar la normalidad y la validez de los análisis estadísticos. Una evaluación adecuada de estos coeficientes ayuda a los investigadores a identificar problemas potenciales en los datos y a tomar medidas correctivas para garantizar resultados precisos y confiables.

Importancia de la Condición de No Multicolinealidad en SEM

La condición de **no multicolinealidad** es fundamental en los Modelos de Ecuaciones Estructurales (SEM) porque asegura que las

variables exógenas incluidas en el modelo no estén altamente correlacionadas entre sí. Esto es crucial para que las estimaciones de los coeficientes sean estables y para garantizar interpretaciones precisas. Cuando las variables exógenas presentan alta multicolinealidad, el modelo enfrenta problemas como:

1. **Inflación de errores estándar:** La multicolinealidad aumenta los errores estándar de los coeficientes, lo que reduce la significancia estadística de las variables, incluso si tienen un efecto real importante (Hair et al., 2021).
2. **Problemas de identificación:** La redundancia en las variables dificulta distinguir los efectos individuales de cada una sobre las variables endógenas.
3. **Inestabilidad de los coeficientes:** Los coeficientes se vuelven sensibles a pequeñas variaciones en los datos, comprometiendo la confiabilidad de las inferencias (Kline, 2021).

Ejemplo de Multicolinealidad en SEM

En un modelo que evalúa la intención de compra, un investigador incluye las variables *percepción de calidad* y *satisfacción del cliente*. Si ambas variables tienen un coeficiente de correlación de 0.92, se genera multicolinealidad. Esto dificulta estimar cuál de las dos tiene un efecto más significativo sobre la intención de compra. Una solución sería combinar ambas variables en un único constructo llamado *percepción general del cliente*.

Importancia de los Coeficientes de Correlación ≤ 0.80

En SEM, mantener coeficientes de **correlación entre variables ≤ 0.80** es esencial para evitar problemas de multicolinealidad y garantizar que las variables aporten información

única al modelo. Cuando las correlaciones entre las variables exógenas superan este umbral, los riesgos incluyen:

1. **Redundancia en las Variables:** Altos coeficientes de correlación indican que las variables están midiendo aspectos muy similares, lo que puede inflar la varianza explicada de manera artificial (Hair et al., 2021).
2. **Pérdida de Interpretabilidad:** La correlación excesiva entre variables dificulta separar los efectos únicos de cada una, afectando la claridad en la interpretación de los resultados.

Figura 9

SPSS: Cálculo de la correlación

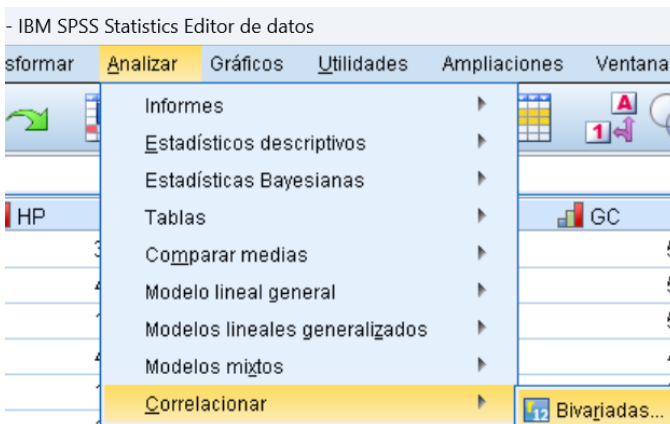




Figura 10

SPSS: Resultado de la correlación

		Correlaciones						
		HP	SP	EP	GC	CLC	CPC	PCP
HP	Correlación de Pearson	1	,683**	,449**	,181**	,125	,064	,245**
	Sig. (bilateral)		,000	,000	,007	,066	,349	,000
	N	219	219	219	219	219	219	219
SP	Correlación de Pearson	,683**	1	,700**	,229**	,251**	,196**	,285**
	Sig. (bilateral)	,000		,000	,001	,000	,004	,000
	N	219	219	219	219	219	219	219
EP	Correlación de Pearson	,449**	,700**	1	,089	,074	,160	,199**
	Sig. (bilateral)	,000	,000		,189	,273	,018	,003
	N	219	219	219	219	219	219	219
GC	Correlación de Pearson	,181**	,229**	,089	1	,374**	,263**	,345**
	Sig. (bilateral)	,007	,001	,189		,000	,000	,000
	N	219	219	219	219	219	219	219

Ejemplo de Correlación Alta en SEM

Un modelo SEM que analiza la satisfacción laboral incluye las variables *relación con los compañeros* y *relación con los supervisores*, que presentan una correlación de 0.85. Esto sugiere que ambas variables podrían estar midiendo el mismo constructo.

Para resolverlo, el investigador puede:

- Reevaluar si ambas variables son necesarias.
- Agruparlas en un único factor latente llamado *relaciones interpersonales*.

Relación entre No Multicolinealidad y Correlaciones ≤ 0.80

El umbral de 0.80 para los coeficientes de correlación es una guía práctica para identificar y prevenir multicolinealidad en los modelos SEM. Aunque los factores con correlaciones entre 0.8 y 0.9 pueden ser manejables en algunos casos, valores más altos suelen comprometer la validez del modelo (Tabachnick & Fidell, 2019). Por esta razón:

- Mantener correlaciones ≤ 0.80 asegura que las variables no sean redundantes.
- Ayuda a garantizar que los modelos sean identificables y sus parámetros estimables.

La condición de no multicolinealidad y el control de coeficientes de correlación ≤ 0.80 son pilares fundamentales en el diseño de modelos SEM robustos. Estas prácticas garantizan que los modelos sean estables, interpretable y que reflejen relaciones causales reales. Los investigadores deben analizar cuidadosamente las correlaciones y aplicar soluciones como la combinación o eliminación de variables para mejorar la calidad de sus modelos.

Caso de Estudio: Medición de la Satisfacción del Cliente en el Sector Bancario en Colombia

En este caso, se analizará la satisfacción del cliente como un constructo latente que depende de varios indicadores observables, como la percepción de calidad de servicio, la eficiencia del personal,

la accesibilidad de los servicios y la probabilidad de recomendar el banco a otros.

Definición del Modelo de Satisfacción del Cliente

Variables Latentes:

- **Satisfacción del Cliente:** Constructo central que se infiere a través de varios indicadores observables.

Variables Observadas (Indicadores):

- **Calidad de Servicio (Q1):** Evalúa la percepción del cliente sobre la calidad general del servicio.
- **Atención del Personal (Q2):** Mide la percepción sobre la eficiencia y amabilidad del personal.
- **Accesibilidad de Servicios (Q3):** Representa la facilidad con la que el cliente puede acceder a los servicios bancarios.
- **Probabilidad de Recomendación (Q4):** Evalúa la intención del cliente de recomendar el banco.

TERMINOLOGÍA Y CONCEPTOS BÁSICOS DE SEM

Ecuación Estructural Estándar

La formulación básica de una ecuación estructural en el modelado de ecuaciones estructurales (SEM) se expresa generalmente como:

Efecto Estructural Causal = ΣX + Perturbación

Esta ecuación representa la relación causal entre las variables latentes y observadas en un modelo SEM, donde la "Perturbación" se refiere a los errores o influencias no observadas en el sistema (Kline, 2021).

Variable Estandarizada

Una variable estandarizada tiene una media de cero y una varianza de uno. Esto se hace comúnmente en SEM para simplificar la interpretación de los resultados (Bollen, 2019).

Variable Latente

Las variables latentes son aquellas que no se miden directamente, sino que se infieren a partir de otras variables observadas. Estas variables latentes representan constructos teóricos no observables, como la inteligencia o la satisfacción (Byrne, 2020).

Variables Exógenas y Endógenas

Las variables exógenas no son causadas por otras variables en el modelo, mientras que las variables endógenas son el resultado de otras variables dentro del modelo. Las variables endógenas pueden actuar también como causas para otras variables endógenas (Kenny, 2020).

Coefficiente Estructural

Un coeficiente estructural mide el cambio en la variable efecto dado un cambio en la variable causal, manteniendo constante el efecto de otras variables (Hair et al., 2019).

Perturbación

En SEM, la perturbación representa el conjunto de factores no especificados que afectan a una variable endógena. Se asemeja a un término de error en un modelo de regresión tradicional y se trata como una variable latente (Schumacker & Lomax, 2020).

Diagrama de Ruta

El diagrama de ruta en SEM es una representación visual del modelo estructural, donde las variables latentes se representan mediante óvalos y las variables observadas por rectángulos. Los caminos causales entre variables se representan con líneas rectas,

mientras que las asociaciones no analizadas se muestran mediante líneas curvas (Kline, 2021); Ejemplo:

El diagrama de ruta es una representación gráfica de la estructura de un modelo de ecuación. En este diagrama, las líneas curvas indican asociaciones no analizadas. Las variables observadas se representan mediante cuadros, mientras que las variables latentes, incluidas las perturbaciones, se muestran como óvalos. Las covarianzas o correlaciones entre las variables exógenas y entre las perturbaciones se representan mediante líneas curvas con flechas en ambos extremos. Las relaciones causales están representadas por líneas rectas con una flecha apuntando desde la variable causal hacia la variable efecto.

En un diagrama de ruta, no se permite una línea curva para una variable endógena. Si se necesita representar una correlación, esta debe extraerse de las variables de perturbación.


$$X3 = aX1 + bX2 + U1$$

$$X4 = cX1 + dX2 + eX3 + U2$$

Tenga en cuenta que X3 y X4 son endógenos (es decir, causados), X1 y X2 son exógenos (no causado), y U1 y U2 son perturbaciones. Nota esa variable endógena X3 es tanto una causa como un efecto variable. El diagrama de ruta para esto el modelo es el siguiente:

Figura 11

Modelo SEM: Descripción



Nota: Tomado de: <https://davidakenny.net/img/pathd.bmp>

Tenga en cuenta que las perturbaciones tienen caminos de uno en el sentido de que hay uno implícito en las ecuaciones estructurales. Nota también que las perturbaciones están representadas por óvalos.

Regla de Rastreo

La regla de rastreo en SEM establece que la correlación entre dos variables es la suma de los productos de las rutas o correlaciones en cada trazo. Esta regla solo se aplica a modelos jerárquicos, sin retroalimentación (Bentler, 2022).

Identificación y Grados de Libertad

Un modelo está identificado cuando hay suficiente información para estimar los parámetros de manera única. Los grados de libertad en SEM se calculan restando el número de parámetros desconocidos del número de valores observados, y son esenciales para evaluar el ajuste del modelo (Hox et al., 2020).

Tipos de Modelos

1. **Justo Identificado o Saturado:** Un modelo donde los parámetros libres igualan exactamente el número de valores conocidos.

2. **Subidentificado:** No permite estimar todos los parámetros del modelo.
3. **Sobreidentificado:** Existen más valores conocidos que parámetros libres, lo cual facilita el ajuste del modelo (Brown, 2019).

Modelo de Ajuste

El ajuste de un modelo SEM se refiere a la capacidad del modelo para replicar la matriz de covarianza de las variables observadas. Esto se evalúa mediante indicadores de ajuste como el RMSEA, CFI y TLI (Hu & Bentler, 1999).

Pasos de modelado de ecuaciones estructurales

- PASO 1: Especificación

Declaración del modelo teórico, ya sea como un conjunto de ecuaciones estructurales o como un diagrama de ruta (Kline, 2021).

- PASO 2: Identificación

Asegurarse de que el modelo pueda estimarse correctamente. Un modelo identificado tiene una solución única para cada parámetro (Bentler, 2022).

- PASO 3: Estimación

Los parámetros del modelo se calculan estadísticamente. En SEM, se suelen emplear métodos como el de máxima verosimilitud o estimadores de mínimos cuadrados (Bollen, 2019).

- PASO 4: Ajuste del Modelo

Comparar las correlaciones o covarianzas estimadas con las observadas para evaluar el ajuste del modelo. Si el ajuste es deficiente, puede ser necesario reespecificar el modelo y volver al primer paso (Hair et al., 2019).

Construcción del Modelo en Software SEM: AMOS y JAMOVI

En este modelo SEM, la "Satisfacción del Cliente" se define como una variable latente explicada por las variables observadas Q1, Q2, Q3 y Q4. Utilizando AMOS y JAMOVI, se pueden crear diagramas y modelos para representar visualmente las relaciones y calcular los parámetros del modelo.

Ejemplo de Esquema Gráfico en AMOS y JAMOVI

Para construir el modelo en AMOS o JAMOVI, se deben seguir los pasos básicos para crear y evaluar un modelo SEM:

1. **Definir la Variable Latente:** En AMOS, se utiliza un círculo para representar la variable latente "Satisfacción del Cliente".
2. **Agregar las Variables Observadas:** Las variables observadas (Q1, Q2, Q3 y Q4) se representan mediante rectángulos.
3. **Dibujar las Flechas:** Conectar la variable latente "Satisfacción del Cliente" con las variables observadas mediante flechas, indicando que estas últimas son indicadores del constructo latente.


Esquema Gráfico:

- **Variable Latente (Círculo):**
 - Satisfacción del Cliente
- **Variables Observadas (Rectángulos):**
 - Q1: Calidad de Servicio
 - Q2: Atención del Personal
 - Q3: Accesibilidad de Servicios
 - Q4: Probabilidad de Recomendación

La conexión entre la variable latente y cada indicador observacional se representa mediante flechas, indicando que los valores de Q1 a Q4 explican parcialmente el nivel de satisfacción del cliente como se muestra en la siguiente figura:

Figura 12

Modelo SEM: Variables Latentes y observadas.



Ejemplo Gráfico para Construir en AMOS o JAMOVI:

1. En AMOS:

- Crear un círculo para la variable "Satisfacción del Cliente".
- Dibujar rectángulos para cada variable observada (Q1, Q2, Q3, Q4).
- Conectar el círculo con cada rectángulo mediante flechas unidireccionales.

- Ejecutar el análisis para calcular las cargas factoriales, que muestran el grado de relación entre la satisfacción del cliente y cada indicador.

2. En JAMOSVI:

- Usar el módulo SEM disponible para definir el modelo.
- Especificar la variable latente y agregar las variables observadas como indicadores.
- JAMOSVI generará el diagrama SEM, mostrando las relaciones y permitiendo visualizar los coeficientes estandarizados.

Análisis de los Resultados y Validación del Modelo

En este caso, una vez que el modelo está construido en AMOS o JAMOSVI, se realiza el análisis estadístico para evaluar la fiabilidad y validez del modelo:

- **Cargas Factoriales:** Determinan qué tan bien cada variable observada explica el constructo de satisfacción del cliente.
- **Índices de Bondad de Ajuste:** Se utilizan para evaluar si el modelo se ajusta adecuadamente a los datos. Los índices comunes incluyen el RMSEA, el CFI y el TLI, donde un buen ajuste se refleja en valores de $RMSEA < 0.06$ y CFI y $TLI > 0.90$.

En el análisis de satisfacción del cliente, un ajuste adecuado indicaría que las variables observadas (Q1, Q2, Q3, Q4) representan con precisión el constructo de "Satisfacción del Cliente" y que el modelo SEM es válido para estudiar este fenómeno en el contexto del sector bancario en Colombia.

Este capítulo ha presentado una revisión detallada sobre la clasificación y medición de variables latentes y observadas en el contexto de SEM, con un caso práctico de satisfacción del cliente en el sector bancario. La construcción de modelos SEM en software como AMOS y JAMOVI permite a los investigadores validar la estructura de estos modelos y proporciona un marco sólido para medir constructos abstractos, facilitando la toma de decisiones informadas en ciencias empresariales y sociales.

CAPITULO IV

Capítulo 4: Modelo de Medición

El modelo de medición en el contexto del Modelo de Ecuaciones Estructurales (SEM) se utiliza para establecer cómo se representan y relacionan las variables observadas y latentes en un modelo estadístico. El objetivo es definir cómo las variables observadas (o indicadores) reflejan o miden constructos no observables directamente, conocidos como variables latentes. En ciencias empresariales y sociales, este tipo de análisis es fundamental, ya que permite cuantificar conceptos abstractos como la calidad, la satisfacción o la percepción mediante indicadores específicos y medibles (Kline, 2016).

Análisis Factorial Confirmatorio (AFC) y su Aplicación en SEM

El Análisis Factorial Confirmatorio (AFC) es una técnica estadística utilizada en SEM para validar si los datos observados se ajustan a un modelo teórico de estructura factorial específico. Mientras que el análisis factorial exploratorio (AFE) busca descubrir la estructura subyacente de un conjunto de datos, el AFC verifica hipótesis predefinidas acerca de cómo se agrupan las variables observadas en factores específicos (Brown, 2015).

En el contexto de SEM, el AFC permite especificar un modelo de medición en el que las variables observadas están vinculadas a variables latentes específicas basadas en una teoría subyacente o un modelo conceptual previo. Al implementar el AFC

en SEM, el investigador puede determinar la calidad y consistencia de los constructos, evaluando qué tan bien las variables observadas representan las variables latentes. Los índices de ajuste, como el RMSEA, CFI y TLI, son fundamentales para evaluar la adecuación del modelo (Hu & Bentler, 1999).

Ejemplo de Análisis Factorial Confirmatorio en Ciencias Sociales

En estudios sobre calidad de vida en el trabajo, por ejemplo, las variables observadas pueden incluir ítems sobre ambiente laboral, equilibrio entre trabajo y vida personal, y oportunidades de desarrollo, mientras que las variables latentes serían los factores que representan la satisfacción laboral y el bienestar (Bollen, 1989). Utilizando SEM con AFC, un investigador podría evaluar si cada ítem contribuye adecuadamente a sus factores latentes asociados y si el modelo teórico propuesto para la satisfacción laboral es consistente con los datos observados.

Caso de Estudio: Evaluación de la Calidad Educativa en Instituciones Peruanas de Educación Superior

En el ámbito de la educación superior en Perú, medir la **calidad educativa** es un objetivo fundamental para los investigadores, gestores y responsables de políticas educativas. A través de SEM y, específicamente, mediante el Análisis Factorial Confirmatorio, se puede desarrollar y validar un modelo para medir constructos como la calidad educativa, utilizando indicadores observados específicos (Vargas & Rojas, 2022).

1. Planteamiento del Modelo de Medición:

Para este caso, consideremos que queremos evaluar la calidad educativa a través de tres dimensiones latentes:

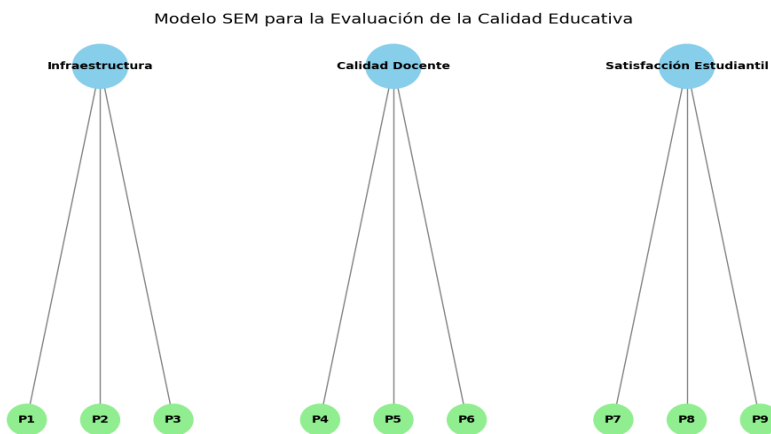
- **Infraestructura:** Recursos físicos y tecnológicos disponibles en la institución.
- **Calidad Docente:** Competencias, conocimientos y habilidades del personal docente.
- **Satisfacción Estudiantil:** Percepción de los estudiantes sobre la enseñanza y el ambiente educativo.

Cada dimensión se medirá mediante varias variables observadas, como se muestra a continuación:

- **Infraestructura:** calidad de aulas, acceso a laboratorios, recursos bibliográficos.
- **Calidad Docente:** evaluación de competencias docentes, actualización académica, relación con estudiantes.
- **Satisfacción Estudiantil:** nivel de satisfacción con los servicios, ambiente de aprendizaje, apoyo institucional.

Figura 13

Modelo SEM: Calidad educativa.



2. Aplicación del Análisis Factorial Confirmatorio (AFC):

Para verificar que el modelo de medición refleja adecuadamente la calidad educativa, se puede aplicar un AFC utilizando un software SEM como AMOS o Mplus. Esto implicará probar si los indicadores observados de cada dimensión (infraestructura, calidad docente, satisfacción estudiantil) representan bien a su constructo latente.

En un estudio hipotético, se recopiló información de estudiantes mediante un cuestionario, y se analizaron los datos en un AFC. Los resultados de este análisis pueden revelar si los ítems asociados a "Calidad Docente" se agrupan en un único factor latente, o si las preguntas de "Satisfacción Estudiantil" reflejan adecuadamente el constructo.

3. Ejemplo Gráfico del Modelo de Medición en SEM:

Para una representación gráfica en SEM, se utiliza un diagrama en el cual:

- Los círculos representan los constructos latentes (Infraestructura, Calidad Docente y Satisfacción Estudiantil).
- Los rectángulos corresponden a las variables observadas.
- Las flechas unidireccionales muestran la relación de cada constructo latente con sus variables observadas.

Una vez establecido el modelo, se procede a evaluar su ajuste mediante índices de ajuste como el RMSEA (< 0.06), el CFI (> 0.90) y el TLI (> 0.90), que ayudan a determinar si el modelo es adecuado (Hu & Bentler, 1999). En caso de obtener un ajuste

insuficiente, se puede mejorar el modelo considerando modificaciones teóricamente justificadas.

4. Resultados y Conclusiones del Estudio

Este análisis proporcionaría una confirmación de si la estructura teórica de la calidad educativa en las instituciones superiores de Perú se ajusta bien a los datos empíricos. La evaluación de la calidad educativa, basada en constructos latentes como la infraestructura y la satisfacción estudiantil, permite obtener insights profundos que ayudan a los gestores universitarios a mejorar la experiencia estudiantil y la percepción pública sobre la institución.

El uso de SEM, y en particular del AFC, permite validar modelos teóricos complejos en ciencias empresariales y sociales. En el contexto de la evaluación de la calidad educativa, el AFC proporciona una metodología robusta para asegurarse de que los indicadores observados representan adecuadamente constructos abstractos, mejorando así la precisión y relevancia de las investigaciones en educación superior (Vargas & Rojas, 2022).

Caso Práctico: Medición de la Satisfacción del Cliente en un Banco

Para desarrollar un caso práctico utilizando el programa AMOS 23, propongo un ejemplo que aborda la evaluación de la **satisfacción del cliente en un banco** a través de variables latentes y observadas. En este caso, se medirá la satisfacción del cliente como un constructo latente utilizando indicadores observados como la calidad del servicio, la probabilidad de recomendación y la

satisfacción general. A continuación, detallo los pasos para realizar el análisis en AMOS 23.

Objetivo del Caso Práctico

El objetivo es construir y analizar un modelo de medición que evalúe la satisfacción del cliente en el sector bancario, usando el Análisis Factorial Confirmatorio (AFC) en AMOS 23. Este caso incluirá tanto las variables observadas como las variables latentes necesarias para representar el constructo.

Paso 1: Preparación de los Datos

1. Definir las Variables Observadas y Latentes:

- **Variable latente (Satisfacción del Cliente):** Representa el constructo que queremos medir.
- **Variables observadas:**
 - **Calidad del Servicio:** Indicador medido en una escala de Likert del 1 al 5 (donde 1 = Muy insatisfecho y 5 = Muy satisfecho).
 - **Probabilidad de Recomendación:** Indicador medido en una escala de Likert del 1 al 5.
 - **Satisfacción General:** Indicador medido en una escala de Likert del 1 al 5.

2. **Ingresar Datos en SPSS:** Crear una base de datos en SPSS con las variables observadas. Cada columna representa un indicador (por ejemplo, Calidad_Servicio, Probabilidad_Recomendacion, Satisfaccion_General) y cada fila corresponde a una respuesta de un cliente.

Paso 2: Importar los Datos a AMOS

1. **Abrir AMOS.**
2. **Importar Datos:** En AMOS, haga clic en File > Data Files y seleccione el archivo de SPSS (.sav) que contiene los datos de los indicadores.

Paso 3: Construcción del Modelo de Medición en AMOS

1. **Crear la Variable Latente:**
 - En la ventana de diseño de AMOS, seleccione la herramienta de creación de variables latentes (círculo) y dibuje un círculo que representará el constructo de **Satisfacción del Cliente**.
2. **Agregar Variables Observadas:**
 - Utilice la herramienta de creación de variables observadas (rectángulo) para crear tres rectángulos, cada uno de los cuales representa un indicador:
 - **Calidad del Servicio**
 - **Probabilidad de Recomendación**
 - **Satisfacción General**
3. **Enlazar las Variables:**
 - Seleccione la herramienta de flecha y dibuje líneas desde el círculo de **Satisfacción del Cliente** a cada una de las variables observadas. Esto indica que las variables observadas son manifestaciones del constructo latente.
4. **Incluir Errores:**

- AMOS automáticamente incluirá términos de error para cada variable observada. Asegúrese de que estén correctamente asignados.

Paso 4: Especificar el Modelo y Ejecutar el Análisis

1. Nombrar las Variables:

- Asigne nombres a cada variable en el modelo haciendo clic en cada rectángulo (variable observada) y en el círculo (variable latente). Esto ayuda a identificar los indicadores y el constructo.

2. Configurar el Análisis:

- En el menú principal, seleccione Analysis Properties. Asegúrese de que esté seleccionada la opción de estimación Maximum Likelihood, comúnmente utilizada en SEM.

3. Ejecutar el Modelo:

- Haga clic en el botón de ejecutar (el icono de la calculadora) para procesar el análisis.

Paso 5: Interpretación de los Resultados

1. Evaluación de los Coeficientes de Carga Factorial:

- En los resultados, revise los coeficientes de carga de cada indicador en la variable latente. Las cargas factoriales deben ser altas (generalmente >0.5) para indicar una buena relación entre las variables observadas y el constructo latente.

2. Índices de Ajuste:

- Revise los índices de ajuste del modelo como el CFI (Comparative Fit Index), TLI (Tucker-Lewis Index), RMSEA (Root Mean Square Error of Approximation) y SRMR (Standardized Root Mean Square Residual). Valores aceptables de ajuste son:
 - CFI y TLI > 0.90 .
 - RMSEA < 0.08 .
 - SRMR < 0.08 .

3. Interpretación del Modelo:

- Si el modelo tiene un buen ajuste, podemos concluir que el constructo de Satisfacción del Cliente está bien representado por las variables observadas Calidad del Servicio, Probabilidad de Recomendación y Satisfacción General.

Paso 6: Reporte de Resultados

En el reporte de resultados, incluya:

1. **Descripción del Modelo:** Explicación del constructo latente y de cada indicador utilizado.
2. **Resultados del Ajuste del Modelo:** Informe sobre los índices de ajuste, indicando que el modelo es válido si se cumplen los criterios de ajuste.
3. **Conclusiones:** Analice los resultados y cómo se relacionan con la satisfacción del cliente en el sector bancario.

Ejemplo de Interpretación de Resultados

Supongamos que obtenemos los siguientes resultados:

- **Calidad del Servicio** tiene una carga factorial de 0.72,
- **Probabilidad de Recomendación** tiene una carga factorial de 0.68,
- **Satisfacción General** tiene una carga factorial de 0.75.

Los índices de ajuste muestran un CFI de 0.95, TLI de 0.92, RMSEA de 0.05 y SRMR de 0.04, indicando un buen ajuste del modelo.

Estos resultados sugieren que el constructo de Satisfacción del Cliente está adecuadamente representado por los indicadores seleccionados, lo cual es crucial para estudios que busquen entender y mejorar la percepción de satisfacción en el sector bancario.

Este caso práctico ilustra cómo estructurar y analizar un modelo de medición con SEM en AMOS 23, ayudando a los investigadores a comprender cómo los indicadores observados reflejan constructos complejos.

Caso Práctico: Evaluación de la Satisfacción Laboral en Recursos Humanos

Para este caso práctico en Jamovi (versión 2.3.28), utilizaremos el análisis de satisfacción laboral en el sector de recursos humanos de una empresa. Analizaremos tres factores clave de la satisfacción laboral como variables latentes: **Compensación**, **Ambiente de Trabajo**, y **Oportunidades de Crecimiento**. Cada factor será evaluado mediante indicadores observados medidos a través de una encuesta.

Objetivo del Caso Práctico

El objetivo es realizar un Análisis Factorial Confirmatorio (AFC) en Jamovi para verificar cómo los factores latentes de satisfacción laboral (Compensación, Ambiente de Trabajo y

Oportunidades de Crecimiento) se relacionan con sus respectivos indicadores observados.

Paso 1: Preparación de los Datos

1. Definir las Variables Observadas y Latentes:

- **Variables latentes:**
 - **Compensación**
 - **Ambiente de Trabajo**
 - **Oportunidades de Crecimiento**
- **Variables observadas:**
 - **Compensación:** Salario Competitivo, Beneficios, Pagos Extraordinarios.
 - **Ambiente de Trabajo:** Relación con Jefes, Relación con Compañeros, Seguridad Laboral.
 - **Oportunidades de Crecimiento:** Capacitación, Oportunidades de Ascenso, Reconocimiento.

2. Recopilar Datos:

- Realizar una encuesta a los empleados, usando una escala de Likert del 1 al 5 para cada indicador.
- Ingresar los datos en una hoja de cálculo o directamente en Jamovi.

Paso 2: Ingresar los Datos en Jamovi

1. **Abrir Jamovi** y cargar la hoja de datos o introducir los datos manualmente.

2. Asegurarse de que las variables observadas (indicadores) estén correctamente etiquetadas.

Paso 3: Instalación del Módulo SEM en Jamovi

1. En Jamovi, diríjase a la pestaña Modules (Módulos) y busque el módulo SEM.
2. Instale el módulo para habilitar las funciones necesarias para el Análisis Factorial Confirmatorio.

Paso 4: Construcción del Modelo en Jamovi

1. **Acceder al Módulo SEM:** Una vez instalado, seleccione el módulo SEM desde la interfaz de Jamovi.
2. **Especificar el Modelo:**
 - Seleccione la opción para crear un nuevo modelo SEM.
 - Defina las variables latentes **Compensación**, **Ambiente de Trabajo**, y **Oportunidades de Crecimiento**.
 - Asigne las variables observadas correspondientes a cada variable latente:
 - **Compensación:** Salario Competitivo, Beneficios, Pagos Extraordinarios.
 - **Ambiente de Trabajo:** Relación con Jefes, Relación con Compañeros, Seguridad Laboral.
 - **Oportunidades de Crecimiento:** Capacitación, Oportunidades de Ascenso, Reconocimiento.
3. **Dibujar el Modelo:**

- En la interfaz del módulo, conecte cada variable latente con sus respectivas variables observadas, estableciendo las relaciones de causalidad entre ellas.
- Agregue los términos de error en cada variable observada (Jamovi SEM agrega estos automáticamente).

Paso 5: Configuración y Ejecución del Modelo

1. Especificar la Configuración:

- Seleccione Estimación Máxima de Verosimilitud (Maximum Likelihood Estimation) como método de estimación, que es el más común en SEM.

2. Ejecutar el Análisis:

- Haga clic en Run o Ejecutar para procesar el modelo.

Paso 6: Interpretación de los Resultados

1. Revisar Cargas Factoriales:

- Observe las cargas factoriales de cada indicador en su respectiva variable latente. Las cargas altas (idealmente >0.5) indican que las variables observadas están bien relacionadas con el constructo.

2. Índices de Ajuste del Modelo:

- Revise los índices de ajuste como el CFI (Índice de Ajuste Comparativo), TLI (Índice de Tucker-Lewis), RMSEA (Raíz del Error Cuadrático Medio de Aproximación) y SRMR (Raíz del Residuo Cuadrático Medio Estandarizado).
- Criterios aceptables:

- **CFI y TLI > 0.90.**
- **RMSEA < 0.08.**
- **SRMR < 0.08.**

3. Evaluación de la Validez del Modelo:

- Un buen ajuste indicará que las variables observadas son buenos representantes de los constructos de satisfacción laboral.

Paso 7: Reporte de Resultados

En el reporte de resultados, incluya:

1. **Descripción del Modelo:** Una explicación del constructo de satisfacción laboral y de los tres factores principales que lo conforman.
2. **Resultados de Ajuste del Modelo:** Un resumen de los índices de ajuste y un análisis sobre el cumplimiento de los criterios de aceptación.
3. **Conclusión del Estudio:** Un análisis de cómo los factores de Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento contribuyen a la satisfacción laboral en el contexto de la empresa.

Ejemplo de Interpretación de Resultados

Supongamos que obtenemos los siguientes resultados en Jamovi:

- **Compensación:** Salario Competitivo (0.75), Beneficios (0.65), Pagos Extraordinarios (0.70).
- **Ambiente de Trabajo:** Relación con Jefes (0.80), Relación con Compañeros (0.72), Seguridad Laboral (0.68).

- **Oportunidades de Crecimiento:** Capacitación (0.67), Oportunidades de Ascenso (0.73), Reconocimiento (0.77).

Con índices de ajuste $CFI = 0.93$, $TLI = 0.91$, $RMSEA = 0.06$, y $SRMR = 0.05$, se puede concluir que el modelo tiene un buen ajuste. Esto sugiere que el modelo de satisfacción laboral está adecuadamente representado y es una buena herramienta para evaluar la percepción de los empleados en el sector de recursos humanos.

Este caso práctico facilita a los investigadores de recursos humanos entender cómo evaluar factores complejos de satisfacción laboral utilizando Jamovi y el SEM.

Sección 3: Procedimientos y Técnicas de Análisis en SEM

CAPITULO V

Capítulo 5: Modelo Estructural

El modelo estructural en SEM (Structural Equation Modeling) es una herramienta fundamental para analizar las relaciones causales entre variables latentes y observadas, permitiendo a los investigadores explorar dependencias complejas y entender cómo diferentes factores interactúan entre sí dentro de un sistema. Este capítulo detalla la estructura de relaciones causales, analiza los modelos de mediación y moderación, y ofrece un caso de estudio sobre el impacto de la cultura organizacional en el rendimiento de empresas familiares en México.

5.1 Estructura de Relaciones Causales y Análisis de Dependencia

El análisis de dependencia en SEM permite explorar cómo una variable independiente afecta a una variable dependiente en un contexto multivariado (Kline, 2015). A través de SEM, los investigadores pueden evaluar relaciones lineales o no lineales, estableciendo direcciones causales que reflejan hipótesis teóricas subyacentes. Por ejemplo, en estudios de cultura organizacional, se puede investigar cómo distintos aspectos de la cultura afectan el desempeño organizacional, ya sea en términos de eficiencia, innovación o retención de empleados (Byrne, 2016).

Los modelos estructurales están compuestos por dos componentes principales:

1. **Modelos de relación causal directa:** donde las relaciones de causa y efecto están representadas directamente entre dos variables, por

ejemplo, cómo la cultura de innovación impacta directamente en la productividad de los empleados.

2. **Modelos de relación causal indirecta:** se estudian relaciones donde una variable mediadora interviene en el efecto de una variable sobre otra, permitiendo entender mecanismos más profundos de influencia entre constructos (Hoyle, 2019).

5.2 Modelos de Mediación y Moderación en SEM

Modelos de Mediación

Un modelo de mediación explora cómo una variable mediadora explica la relación entre una variable independiente y una variable dependiente. En el contexto empresarial, la mediación puede ser útil para comprender cómo factores intermedios, como el compromiso de los empleados, influyen en la relación entre cultura organizacional y rendimiento organizacional (Hayes, 2018). Por ejemplo, un estudio puede explorar si la cultura de apoyo dentro de una empresa familiar en México impacta el rendimiento empresarial directamente o si, en cambio, lo hace a través de una mayor satisfacción laboral entre los empleados.

Para llevar a cabo este tipo de análisis, se suelen emplear técnicas como el análisis de ruta (path analysis), que permite determinar la proporción de efectos directos e indirectos en el modelo estructural (Preacher & Hayes, 2008).

Modelos de Moderación

Los modelos de moderación, por otro lado, investigan cómo la relación entre una variable independiente y una dependiente varía en función del nivel de una tercera variable, denominada moderadora. En un contexto de empresas familiares en México, se podría analizar cómo la antigüedad de la empresa modera la relación entre la cultura organizacional y el rendimiento empresarial, de

modo que, en empresas más antiguas, la cultura organizacional pueda tener un impacto diferente en el rendimiento en comparación con empresas más jóvenes (Aguinis, 2004).

Los modelos de moderación son particularmente útiles en estudios de ciencias sociales y empresariales, ya que permiten identificar variables contextuales que pueden influir en la fortaleza o dirección de las relaciones entre constructos (Muthén, 2010).

5.3 Caso de Estudio: Impacto de la Cultura Organizacional en el Rendimiento de Empresas Familiares en México

En este caso de estudio, se analiza el impacto de distintos factores de la cultura organizacional en el rendimiento de empresas familiares en México. La cultura organizacional incluye aspectos como el respeto a la tradición, el compromiso con los empleados y la orientación a la innovación. Se busca investigar si estas dimensiones de la cultura organizacional afectan directamente el rendimiento o si dicho efecto es mediado por variables intermedias como la satisfacción y el compromiso de los empleados.

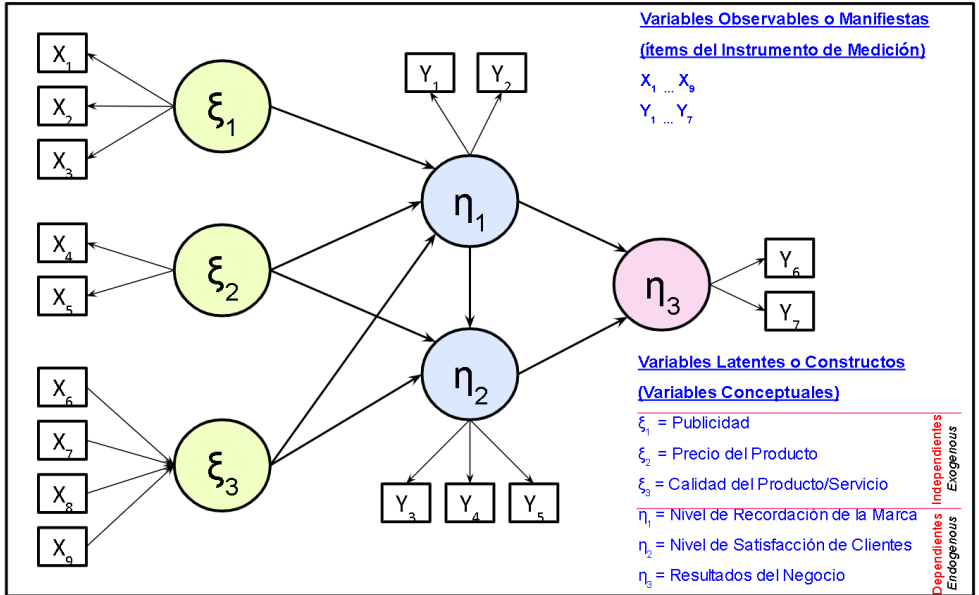
Estructura del Modelo

1. **Variables latentes:** Cultura Organizacional (compuesta por factores como innovación, tradición y compromiso) y Rendimiento Organizacional.
2. **Variables mediadoras:** Satisfacción Laboral y Compromiso de los Empleados.
3. **Variables observadas:** Indicadores específicos de cada factor, como "satisfacción general de los empleados", "nivel de innovación", entre otros.

Modelización de un Modelo de Ecuaciones Estructurales

Figura 14

Modelo conceptual SEM



Nota: Tomado de Saravia (2023) Universidad del Pacifico PIE

Figura 15

Modelo SEM: Parámetros y notaciones

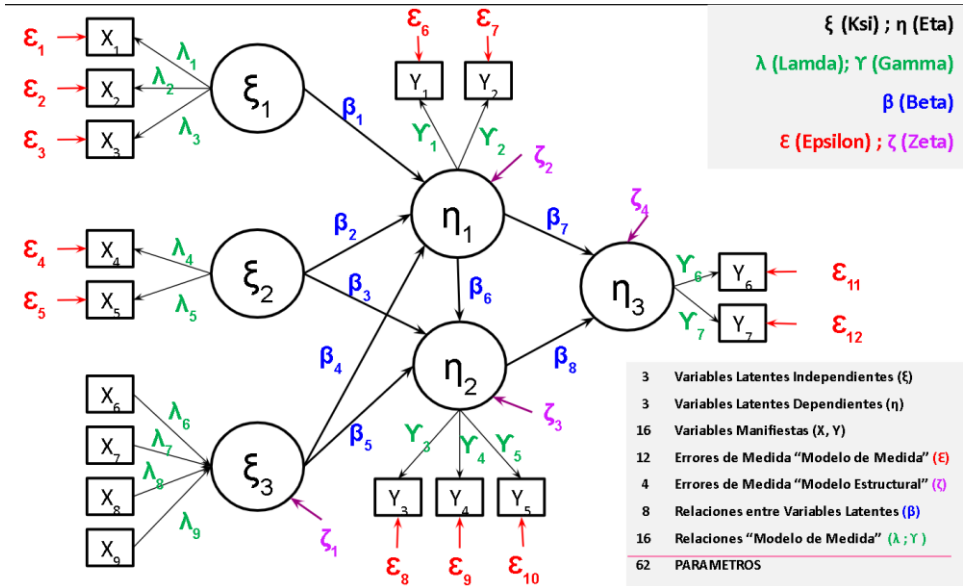




Figura 16

Modelo: Tipo de Relaciones entre variables

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



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



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





Figura 17

SEM: Modelo Teórico e Hipótesis




Nota: Tomado de Saravia (2023) Universidad del Pacifico PIE

Hipótesis

- H_1 : “La inversión en Publicidad influye de manera positiva y significativa en la Recordación de Marca”
- H_2 : “El Precio influye de manera negativa y significativa en la Recordación de Marca” ...
- H_7 : “La Recordación de Marca influye de manera positiva y significativa en los Resultados”
- H_9 : “La Recordación de Marca influye significativamente de manera directa, e indirecta con la Satisfacción como variable mediadora, en los Resultados”

Figura 18

Modelo del factor obligación moral e intención de compra SmartPLS



- *Nota:* Se visualiza la relación entre los constructos de Obligación Moral e Intención de Compra.

Diseño del Estudio y Análisis en SEM

Se utilizaría un software de SEM como AMOS o Mplus para realizar el análisis estructural del modelo. Los pasos incluirían:

1. **Definición de constructos y medición:** El primer paso consiste en definir las variables latentes y sus respectivos indicadores, por ejemplo, el compromiso de los empleados como mediador entre cultura organizacional y rendimiento (Bollen, 1989).
2. **Estimación de relaciones:** Luego, se realizan estimaciones de los efectos directos e indirectos de cada variable, lo que permitirá identificar el papel de la satisfacción laboral y el compromiso como mediadores en el modelo.
3. **Evaluación de ajuste del modelo:** Se revisan los índices de ajuste del modelo, como CFI (Comparative Fit Index), TLI (Tucker-Lewis Index) y RMSEA (Root Mean Square Error of Approximation), para confirmar la validez del modelo estructural propuesto (Schreiber et al., 2006).

Resultados Esperados y Conclusión

En este caso de estudio, se espera encontrar que la cultura organizacional tenga un impacto positivo en el rendimiento empresarial, mediado por la satisfacción y el compromiso de los empleados. Los resultados permitirían a las empresas familiares en México identificar áreas clave de mejora en su cultura organizacional para optimizar su rendimiento. Además, este análisis aporta al campo de estudios empresariales al demostrar cómo un marco estructural puede ayudar a desentrañar las relaciones complejas entre variables organizacionales (Hair et al., 2010).

Caso práctico

Este ejercicio incluye los pasos detallados para construir el modelo en AMOS y analizar las relaciones entre variables latentes y observadas.

Caso Práctico: Impacto de la Cultura Organizacional en el Desempeño Laboral

Objetivo del Caso

Analizar cómo la cultura organizacional influye en el desempeño laboral de los empleados mediante las variables latentes "Cultura Organizacional" y "Desempeño Laboral".

Paso 1: Definir Variables y Constructos

1. Variables Latentes:

- **Cultura Organizacional** (representada por variables observadas: Compromiso, Innovación, y Comunicación).
- **Desempeño Laboral** (representada por variables observadas: Productividad, Calidad del Trabajo, y Satisfacción).

2. Variables Observadas:

- Para *Cultura Organizacional*:
 - Compromiso (medida en una escala de 1 a 5).
 - Innovación (escala de 1 a 5).
 - Comunicación (escala de 1 a 5).
- Para *Desempeño Laboral*:

- Productividad (escala de 1 a 5).
- Calidad del Trabajo (escala de 1 a 5).
- Satisfacción (escala de 1 a 5).

Paso 2: Crear la Base de Datos en SPSS

1. Crea un archivo en SPSS (o en Excel y luego guárdalo como .sav) con las siguientes columnas:
 - Compromiso, Innovación, Comunicación, Productividad, Calidad_Trabajo, Satisfacción.
2. Ingresa un conjunto de datos simulado con valores en una escala de 1 a 5.

Paso 3: Importar la Base de Datos a AMOS

1. Abre AMOS y selecciona "Data Files" para cargar el archivo de datos en formato .sav.
2. Asegúrate de que los nombres de las variables en AMOS coincidan con los nombres en el archivo de datos.

Paso 4: Dibujar el Modelo de SEM en AMOS

1. **Crea los Constructos (Variables Latentes):**
 - Haz clic en el icono de "Ellipse" para dibujar las variables latentes.
 - Dibuja dos elipses y nómbralas como "Cultura Organizacional" y "Desempeño Laboral".
2. **Agregar Variables Observadas:**
 - Usa el icono de "Rectangle" para dibujar cuadros alrededor de los constructos. Agrega tres rectángulos para cada constructo:

- Para *Cultura Organizacional*: conecta las variables Compromiso, Innovación, y Comunicación.
- Para *Desempeño Laboral*: conecta las variables Productividad, Calidad_Trabajo, y Satisfacción.

3. Dibujar las Flechas de Relaciones:

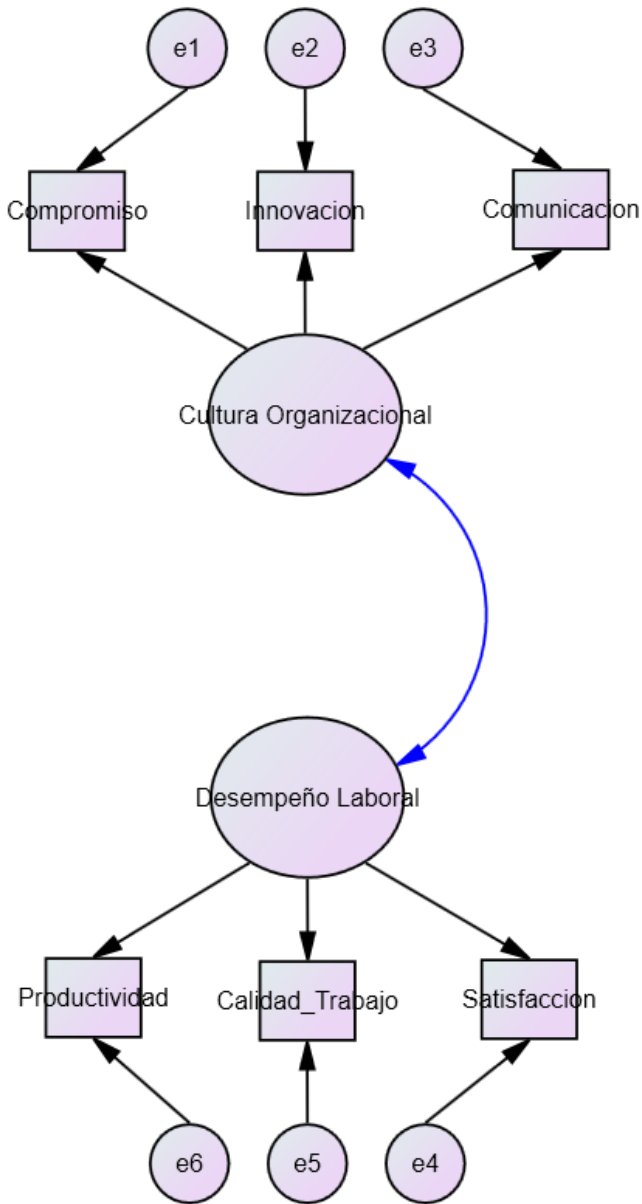
- Usa flechas para conectar las variables latentes con sus respectivas variables observadas.
- Luego, dibuja una flecha de "Cultura Organizacional" hacia "Desempeño Laboral" para establecer una relación causal.

4. Agregar los Errores de Medición:

- AMOS automáticamente asignará un error de medición a cada variable observada. Asegúrate de que cada variable observada tenga un error, representado como círculos pequeños con flechas que conecten al cuadro correspondiente. Así como se aprecia en la siguiente figura:

Figura 19

Modelo SEM: Cultura Organizacional y Desempeño Laboral.

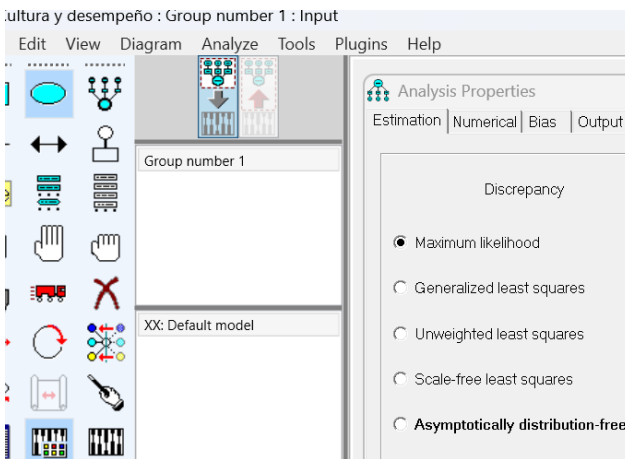


Paso 5: Especificar el Modelo

1. Selecciona las flechas para establecer las relaciones causales entre las variables latentes y observadas.
2. Configura las flechas de cada variable observada a su constructo, asegurándote de que AMOS interprete estas relaciones correctamente.
3. Ve a "Analysis Properties" para seleccionar "Estimation Method" y configura el modelo para análisis estándar con máxima verosimilitud (Maximum Likelihood).

Figura 20

Modelo SEM: Maximum Likelihood.



Paso 6: Ejecutar el Análisis

1. Haz clic en el botón de "Calculate Estimates" para correr el análisis.
2. AMOS mostrará los resultados de estimación, incluyendo:
 - Los coeficientes de las relaciones entre variables.

- Los índices de ajuste del modelo (e.g., CFI, RMSEA, TLI).

Paso 7: Interpretar Resultados

1. **Coefficientes de las Relaciones:** Examina los valores estimados entre "Cultura Organizacional" y "Desempeño Laboral". Un coeficiente positivo indicaría que una mejora en la cultura organizacional tiende a mejorar el desempeño laboral.
2. **Ajuste del Modelo:** Revisa los índices de ajuste (CFI, TLI, RMSEA). Valores de CFI y TLI cercanos a 1 y un RMSEA menor de 0.08 generalmente indican un buen ajuste (Schreiber et al., 2006).

Paso 8: Conclusión

Este análisis SEM en AMOS permite entender cómo la cultura organizacional afecta el desempeño laboral en una empresa simulada. Los resultados de este modelo estructural pueden ayudar a tomar decisiones informadas sobre la mejora de los elementos de la cultura organizacional que influyen positivamente en el desempeño de los empleados.

Capítulo 6: Recopilación y Preparación de Datos

En este capítulo, se abordarán los procesos fundamentales para la recopilación y preparación de datos en la Modelación de Ecuaciones Estructurales (SEM), detallando estrategias específicas para estudios de ciencias sociales y empresariales. Se incluirá un caso práctico sobre la recopilación de datos interculturales en Perú y Ecuador, con un enfoque en los desafíos metodológicos y el análisis de datos en programas como SPSS y Jamovi.

Estrategias para la Recopilación de Datos en SEM

La recopilación de datos para SEM requiere un enfoque cuidadoso, ya que la calidad y naturaleza de los datos son críticos para la precisión de los modelos (Kline, 2016). Para SEM, es esencial diseñar un plan de recopilación de datos que considere tanto las variables observadas como las latentes. Las estrategias más comunes incluyen encuestas estructuradas, entrevistas y cuestionarios que permiten medir las variables observables que representan los constructos latentes.

Ejemplo de Estrategia en el Contexto Empresarial

Para estudiar el impacto de la cultura organizacional en la satisfacción de los empleados, una empresa podría aplicar encuestas que incluyan ítems específicos sobre la comunicación interna, el liderazgo y la relación con los compañeros de trabajo. Los ítems se miden en escalas Likert para reflejar el nivel de acuerdo de los empleados en aspectos clave de la cultura organizacional (Byrne, 2013).

Ejemplo en Ciencias Sociales

Un estudio intercultural sobre el bienestar subjetivo de personas en Perú y Ecuador podría recopilar datos sobre percepciones de bienestar, calidad de vida y satisfacción general. Es importante que el cuestionario esté adaptado culturalmente, teniendo en cuenta el idioma y la relevancia de los

constructos en cada cultura (Cheung et al., 2017). Este tipo de investigación requiere un análisis SEM multinivel, en el cual se incorporen tanto los datos individuales como los factores culturales a nivel grupal.

Procedimientos de Limpieza y Transformación de Datos

La preparación de los datos es esencial para evitar resultados sesgados o inexactos. El análisis SEM es sensible a la calidad de los datos; por ello, la limpieza y transformación de los datos son pasos fundamentales antes del modelado. Este proceso incluye el manejo de valores perdidos, la detección de valores atípicos y la verificación de la normalidad, linealidad y homogeneidad.

1. **Manejo de Valores Perdidos:** Una estrategia es imputar valores mediante el método de media o, en casos más complejos, usando imputación múltiple (Little & Rubin, 2019).
2. **Detección de Valores Atípicos:** Los valores extremos pueden distorsionar el análisis SEM. En SPSS, se pueden detectar usando Z-scores y Mahalanobis distance, mientras que en Jamovi se cuenta con opciones para eliminar casos atípicos de manera similar.
3. **Transformación de Datos:** Si los datos no cumplen con la normalidad, es posible aplicar transformaciones logarítmicas o de raíz cuadrada para mejorar la distribución de las variables, especialmente en análisis SEM donde se asume normalidad multivariante (Muthén & Muthén, 2017).

Procedimiento en SPSS y Jamovi

- En **SPSS**, los valores perdidos pueden ser imputados usando la opción de “Imputación de Datos” en el menú de Análisis de Datos. Para la detección de valores atípicos, se puede utilizar el análisis de regresión y calcular la distancia de Mahalanobis para cada caso.

- En **Jamovi**, la sección “Transform” permite modificar las variables para asegurar su normalidad. La detección de outliers también es sencilla con el módulo de regresión, y la limpieza de datos se facilita a través de la interfaz gráfica.

Caso Práctico: Desafíos en la Recopilación de Datos para Estudios Interculturales en Perú y Ecuador

Este caso práctico se enfoca en los desafíos que enfrentan los investigadores al recolectar datos en estudios interculturales que comparan Perú y Ecuador, específicamente en temas de bienestar subjetivo y calidad de vida en comunidades indígenas. La recopilación de datos interculturales conlleva la dificultad de crear instrumentos que respeten las diferencias culturales y lingüísticas, además de asegurar la comparabilidad entre los grupos.

Paso a Paso del Caso Práctico

1. **Diseño del Cuestionario:** El cuestionario debe incluir ítems que midan el bienestar subjetivo, adaptados culturalmente a los contextos de ambos países. Ejemplos de preguntas incluyen el nivel de satisfacción con la vida y la percepción de apoyo social. Es importante que las escalas de respuesta sean claras para ambas culturas.
2. **Recopilación de Datos en Campo:** Al recolectar los datos en comunidades rurales de Perú y Ecuador, es común encontrar dificultades logísticas como la inaccesibilidad de las localidades y las diferencias en el idioma. Para abordar esto, se recomienda trabajar con traductores locales y realizar entrevistas en persona.
3. **Preparación y Limpieza de los Datos:**
 - **En SPSS:** Para datos de bienestar, los valores atípicos pueden detectarse mediante el análisis de Z-scores y se

puede evaluar la consistencia interna de las escalas usando el Alfa de Cronbach.

- **En Jamovi:** El módulo de estadísticas descriptivas y la detección de outliers ayudan a garantizar que los datos estén limpios y listos para el análisis SEM.

4. **Análisis SEM:** Una vez preparados los datos, el análisis SEM puede realizarse para evaluar la estructura de las relaciones entre el bienestar subjetivo y otros factores, como el apoyo social y la calidad de vida.

Paso a Paso del Caso Práctico: Diseño del Cuestionario en Ciencias Empresariales

Para desarrollar un cuestionario en ciencias empresariales orientado a medir, por ejemplo, la "Satisfacción Laboral y su Impacto en la Productividad de los Empleados," el proceso de diseño del cuestionario debe considerar varios pasos clave para asegurar la precisión y validez de los datos recopilados. A continuación, se desarrolla un paso a paso para crear este cuestionario, tomando en cuenta las recomendaciones para investigaciones SEM y el uso de escalas específicas para los constructos.

Paso 1: Definición de los Constructos

Para un estudio que evalúa la "Satisfacción Laboral y su Impacto en la Productividad," es crucial identificar los constructos latentes clave que se medirán en el análisis SEM, así como las variables observadas que los representarán. En este caso, los constructos podrían incluir:

- **Satisfacción Laboral:** Medido a través de dimensiones como el salario, el ambiente laboral y el reconocimiento.
- **Compromiso Organizacional:** Reflejado en factores como la motivación y lealtad de los empleados.

- **Productividad:** Evaluado mediante indicadores de rendimiento, calidad de trabajo y cumplimiento de metas.

Paso 2: Selección de Ítems para Cada Constructo

Una vez identificados los constructos, el siguiente paso es seleccionar los ítems específicos que se usarán para medir cada uno. Para asegurar la fiabilidad y validez, los ítems deben basarse en escalas previamente validadas en investigaciones empresariales.

Ejemplo de Ítems:

- **Satisfacción Laboral:**
 - “Estoy satisfecho con mi salario actual.”
 - “El ambiente laboral en mi equipo de trabajo es agradable.”
 - “Siento que mi esfuerzo es reconocido por mis superiores.”
- **Compromiso Organizacional:**
 - “Estoy motivado para dar lo mejor de mí en este trabajo.”
 - “Siento un fuerte compromiso con los objetivos de la empresa.”
- **Productividad:**
 - “Cumpro con mis metas laborales en los plazos establecidos.”
 - “Mi trabajo contribuye positivamente a los objetivos de la empresa.”

Paso 3: Determinación de la Escala de Respuesta

Para este tipo de cuestionario, es común utilizar una escala Likert de 5 o 7 puntos, ya que facilita a los participantes expresar su nivel de acuerdo o satisfacción. Una escala de 5 puntos podría ser la siguiente:

1. Totalmente en desacuerdo
2. En desacuerdo
3. Ni de acuerdo ni en desacuerdo
4. De acuerdo
5. Totalmente de acuerdo

Paso 4: Redacción y Formato del Cuestionario

La redacción de los ítems debe ser clara y precisa para evitar ambigüedades. Es fundamental evitar el uso de términos técnicos que los empleados puedan no comprender, así como preguntas que puedan inducir respuestas sesgadas.

Ejemplo de Formato:

Pregunta	1	2	3	4	5
Estoy satisfecho con mi salario actual.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
El ambiente laboral en mi equipo de trabajo es agradable.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Siento que mi esfuerzo es reconocido por mis superiores.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Cumplo con mis metas laborales en los plazos establecidos.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Estoy motivado para dar lo mejor de mí en este trabajo.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

22 Paso 5: Validación Piloto del Cuestionario

Antes de aplicar el cuestionario en el estudio principal, es recomendable realizar una prueba piloto con un pequeño grupo de empleados. Esta validación permite identificar posibles errores en la redacción y en la interpretación de las preguntas, asegurando que los ítems sean comprendidos correctamente.

Paso 6: Administración del Cuestionario

Para maximizar la tasa de respuesta, es importante decidir el método de administración del cuestionario, ya sea en formato físico o digital. Si es digital, se pueden utilizar plataformas como Google Forms o SurveyMonkey (<https://es.surveymonkey.com/>) para recolectar los datos de forma eficiente. Asegurarse de explicar a los participantes el propósito del estudio y de mantener la confidencialidad de sus respuestas.

Paso 7: Preparación de los Datos para el Análisis SEM

Una vez recopilados los datos, es necesario revisarlos y limpiarlos para el análisis SEM. Esto implica la detección de valores perdidos y la verificación de la normalidad de los datos. También se deben transformar y preparar para su análisis en software como SPSS o Jamovi.

Ejemplo Práctico en SPSS y Jamovi

1. **Ingresar Datos:** En SPSS y Jamovi, cada ítem del cuestionario se ingresa como una columna y cada respuesta de los participantes se introduce en las filas.
2. **Verificar Consistencia:** Usar el Alfa de Cronbach en SPSS o en el módulo de fiabilidad de Jamovi para asegurarse de que los ítems de cada constructo son consistentes.
3. **Exploración Inicial:** Realizar un análisis descriptivo para revisar la media y desviación estándar de cada ítem.

Este proceso garantiza que el cuestionario esté diseñado de manera robusta y que los datos obtenidos sean adecuados para el análisis SEM.

Confiabilidad Alfa de Cronbach

El Alfa de Cronbach es una medida ampliamente utilizada en las ciencias sociales, empresariales y del comportamiento para evaluar la confiabilidad de una escala o instrumento de medición en términos de consistencia interna. Esta métrica es fundamental para los estudiantes de nivel superior, ya que es una herramienta esencial en la investigación y análisis de datos.

Según Tavakol y Dennick (2011), "el Alfa de Cronbach es un índice de consistencia interna que varía entre 0 y 1 y permite verificar si el instrumento en evaluación recolecta información precisa o, por el contrario, defectuosa, lo cual podría llevar a conclusiones incorrectas" (p. 53).

¿Qué es el Alfa de Cronbach? El Alfa de Cronbach es un coeficiente que oscila entre 0 y 1, utilizado para medir la confiabilidad de una escala o conjunto de ítems. Un valor cercano a 1 indica que los ítems miden un mismo constructo o dimensión, mientras que un valor cercano a 0 sugiere lo contrario. Su fórmula es:

$$\alpha = \frac{N \cdot \bar{r}}{1 + (N - 1) \cdot \bar{r}}$$

Donde:

- N = número de ítems
- \bar{r} = promedio de las correlaciones entre los ítems

La fórmula se basa en la correlación promedio entre los ítems de una escala. Como señalan Bland y Altman (1997), "un alto valor de alfa generalmente indica que los ítems evalúan un constructo común" (p. 572).

Interpretación del Alfa de Cronbach No existen reglas absolutas sobre los valores aceptables del Alfa de Cronbach, aunque se ofrecen guías generales:

- Alfa ≥ 0.9 : Excelente
- Alfa ≥ 0.8 : Bueno
- Alfa ≥ 0.7 : Aceptable
- Alfa ≥ 0.6 : Cuestionable
- Alfa ≥ 0.5 : Pobre
- Alfa < 0.5 : Inaceptable

Es importante destacar que estos valores son orientativos y que el valor aceptable puede variar según el contexto y los objetivos de la investigación. Como afirma Taber (2018), "no hay un valor de alfa universalmente adecuado para todos los casos" (p. 1279).

Ejemplo Práctico: Supongamos que un investigador realiza una investigación sobre satisfacción laboral utilizando un cuestionario de 10 ítems. Luego de recopilar datos de una muestra de 100 empleados, el estudiante evalúa la confiabilidad de su escala mediante el Alfa de Cronbach, obteniendo un valor de 0.82. Este resultado se considera "bueno" según las pautas generales, lo cual indica que los ítems miden consistentemente el constructo de satisfacción laboral.

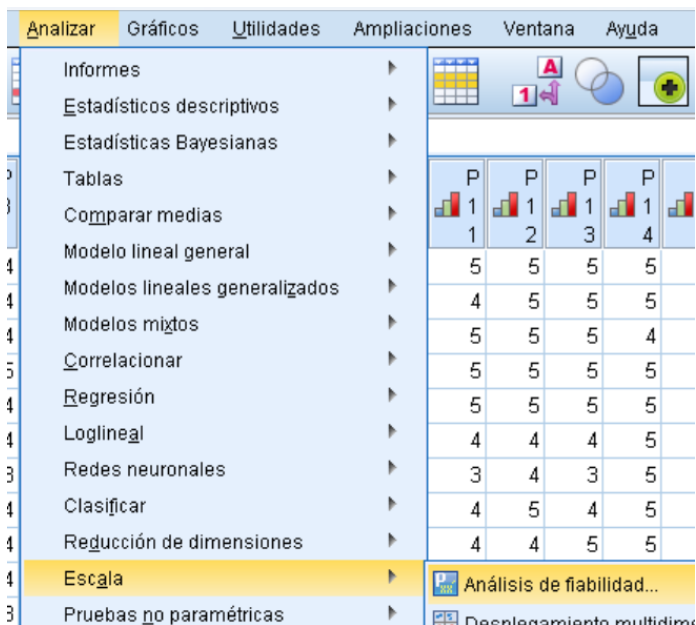
El investigador también puede revisar la matriz de correlación entre los ítems y los valores de Alfa de Cronbach al eliminar cada ítem, lo que permite identificar si algún ítem específico afecta negativamente la confiabilidad.

Caso Práctico: Evaluación de la Confiabilidad de una Escala de Calidad de Atención al Cliente Un grupo de investigadores de administración investiga la calidad de atención al cliente en empresas de servicios mediante una escala de 57 ítems. Luego de recoger datos de 112 clientes, calculan el Alfa de Cronbach, obteniendo un valor de 0,897, lo que indica una buena confiabilidad de la escala.

Paso 1: Calcular el Alfa de Cronbach Usando software estadístico, como SPSS o R, los investigadores obtienen un Alfa de Cronbach de 0,897 para la escala de calidad de atención al cliente.

Figura 21

Procedimiento de fiabilidad en SPSS.

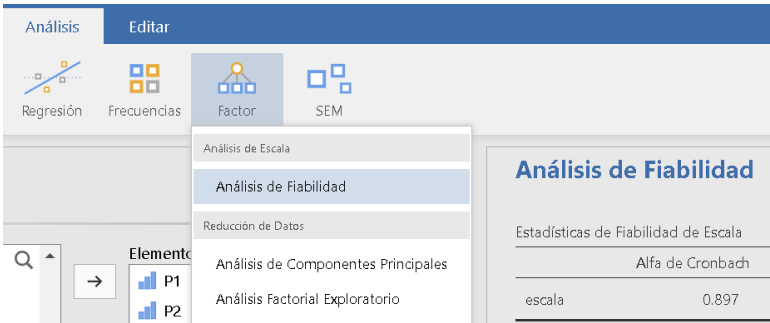


Estadísticas de fiabilidad

Alfa de Cronbach	N de elementos
,897	57

Figura 22

Procedimiento de fiabilidad en Jamovi.



Paso 2: Interpretación Según las guías de interpretación, un Alfa de 0,897 sugiere que los ítems miden consistentemente el constructo de interés; siendo el Alfa ≥ 0.8 : que representa “Bueno”

Paso 3: Análisis de Correlación Ítem-Total Los investigadores también analizan la matriz de correlación *ítem-total* para identificar ítems con baja correlación, lo que podría indicar un impacto negativo en la confiabilidad de la escala.

Figura 23

Procedimiento de correlación en SPSS.

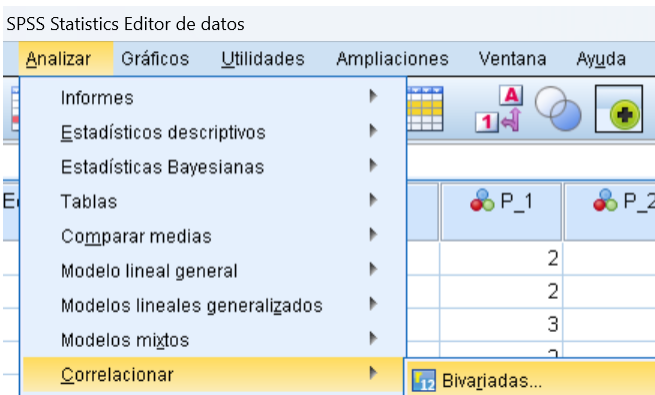


Tabla 1

Matriz de correlaciones SPSS:

		Correlaciones				
		Fomento de asociaciones en economía popular	Plan de acción para control del comercio informal	Ordenamiento de la ciudad	Capacitación de fiscalizadores municipales	Capacitación del personal de actividades económicas
Fomento de asociaciones en economía popular	Correlación de Pearson	1	,404**	,322**	,471**	,436**
	Sig. (bilateral)		,000	,001	,000	,000
	N	104	104	104	104	104
Plan de acción para control del comercio informal	Correlación de Pearson	,404**	1	,358**	,422**	,257**
	Sig. (bilateral)	,000		,000	,000	,008
	N	104	104	104	104	104
Ordenamiento de la ciudad	Correlación de Pearson	,322**	,358**	1	,348**	,302**
	Sig. (bilateral)	,001	,000		,000	,002
	N	104	104	104	104	104
Capacitación de fiscalizadores municipales	Correlación de Pearson	,471**	,422**	,348**	1	,409**
	Sig. (bilateral)	,000	,000	,000		,000
	N	104	104	104	104	104
Capacitación del personal de actividades económicas	Correlación de Pearson	,436**	,257**	,302**	,409**	1
	Sig. (bilateral)	,000	,008	,002	,000	
	N	104	104	104	104	104

** La correlación es significativa en el nivel 0,01 (bilateral).

Tabla 2

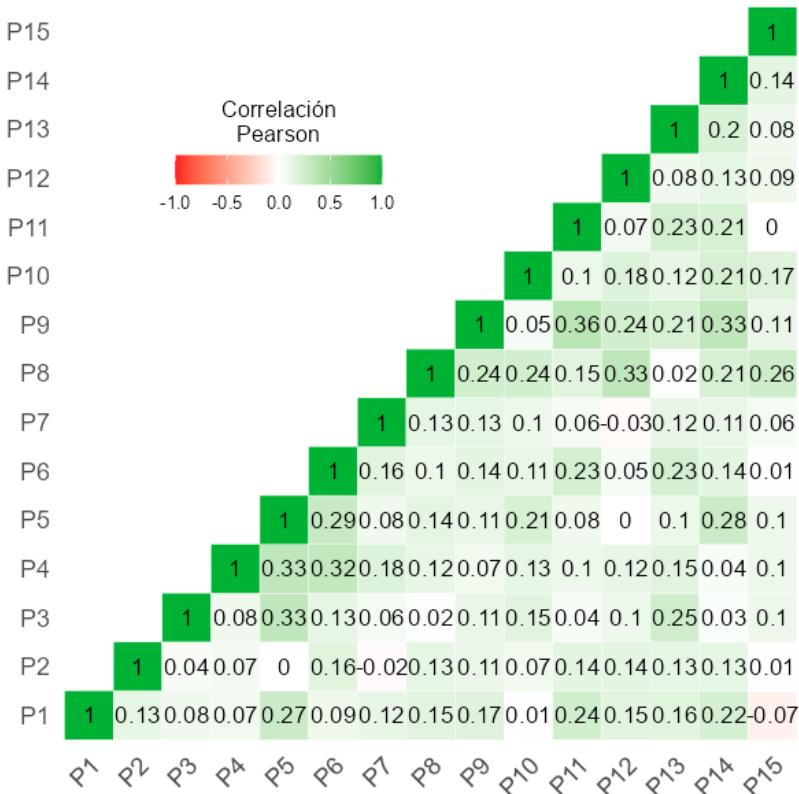
Matriz de correlaciones Jamovi:

Estadísticas de Fiabilidad de Elemento

	DE	Correlación del elemento con otros	Si se descarta el elemento	
			Alfa de Cronbach	ω de McDonald
P1	1.32	0.287	0.684	0.686
P2	1.40	0.199	0.694	0.696
P3	1.30	0.243	0.688	0.692
P4	1.47	0.305	0.681	0.685
P5	1.47	0.374	0.673	0.675
P6	1.39	0.352	0.676	0.679
P7	1.47	0.197	0.694	0.697
P8	1.53	0.372	0.673	0.678
P9	1.50	0.391	0.670	0.674
P10	1.53	0.299	0.682	0.686
P11	1.50	0.322	0.679	0.682
P12	1.53	0.266	0.686	0.689
P13	1.35	0.333	0.678	0.681
P14	1.43	0.396	0.670	0.673
P15	1.51	0.190	0.696	0.698

Figura 24

Correlación: Mapa de calor en Jamovi.



Paso 4: Toma de Decisiones Tras evaluar los resultados, los investigadores deciden mantener todos los ítems, respaldados por un alto Alfa de Cronbach (0,897) y correlaciones positivas en el ítem-total.

En resumen, el cálculo del Alfa de Cronbach es un paso esencial en la evaluación de la confiabilidad de instrumentos de medición en investigaciones de nivel superior, permitiendo asegurar la consistencia y estabilidad de los resultados.

Nota: La confiabilidad se mide en términos de *estabilidad* y *consistencia interna del instrumento* de investigación. La estabilidad implica que el instrumento produce datos consistentes cuando se aplica en condiciones

similares, mientras que la consistencia interna se refiere a la precisión con la que cada parte del instrumento mide en forma similar (Guevara, 2016).

Capítulo 7: Evaluación y Ajuste de Modelos SEM

La evaluación y ajuste de modelos en SEM es una fase crítica en la cual se determina si el modelo propuesto representa adecuadamente los datos. Para medir la calidad de ajuste, los investigadores emplean distintos índices de ajuste y criterios de evaluación. Este capítulo se centrará en estos índices, proporcionando ejemplos prácticos sobre cómo utilizarlos en el ajuste de un modelo de compromiso organizacional en empresas mineras de Chile y Perú. Además, se ilustrarán procedimientos específicos en los programas SPSS, AMOS y Jamovi.

Índices de Ajuste y Criterios de Evaluación de Modelos SEM

Para evaluar un modelo SEM, existen índices que se agrupan en varias categorías, cada una de las cuales ofrece información específica sobre el ajuste del modelo. Los índices más comunes son:

1. **Chi-Cuadrado de Bondad de Ajuste (χ^2):** Este índice evalúa la discrepancia entre el modelo y los datos observados. Idealmente, un valor de χ^2 no significativo indica un buen ajuste, aunque este índice es sensible al tamaño de muestra (Kline, 2015).
2. **Índice de Ajuste Comparativo (CFI):** Este índice compara el ajuste del modelo con un modelo nulo en el que no existen relaciones entre las variables. Valores de **CFI mayores a 0.90** indican un ajuste aceptable, mientras que valores superiores a 0.95 son indicativos de un buen ajuste (Bentler, 1990).
3. **Índice de Ajuste de Tucker-Lewis (TLI):** Este índice, similar al CFI, penaliza modelos más complejos. Valores superiores a 0.90 indican un ajuste aceptable y valores superiores a 0.95 son ideales (Hu & Bentler, 1999).
4. **Raíz del Error Cuadrático Medio de Aproximación (RMSEA):** El RMSEA evalúa la falta de ajuste y ajusta la complejidad del

modelo. **Valores menores a 0.06** indican un buen ajuste, y valores entre 0.06 y 0.08 se consideran aceptables (Browne & Cudeck, 1993).

5. **SRMR (Raíz Cuadrada Media de los Residuos Estándarizados):** Un SRMR inferior a 0.08 indica un ajuste adecuado (Byrne, 2016).

Caso de Estudio: Ajuste de un Modelo de Compromiso Organizacional en Empresas Mineras de Chile y Perú

En este caso, se investigará el compromiso organizacional en empresas mineras de Chile y Perú, evaluando factores como la **satisfacción laboral, identificación con la empresa y lealtad**. El objetivo es verificar si el modelo SEM de compromiso organizacional es adecuado y se ajusta bien a los datos.

Constructos y Variables Observadas

1. **Satisfacción Laboral:** Medida a través de ítems como “Estoy satisfecho con mi salario” y “Las condiciones de trabajo son adecuadas”.
2. **Identificación con la Empresa:** Ítems incluyen “Me siento identificado con la misión de la empresa” y “Creo en los valores de la empresa”.
3. **Lealtad:** Incluye ítems como “Me veo trabajando en esta empresa en los próximos años” y “Recomendaría esta empresa a otros”.

Procedimiento en Software SPSS, AMOS y Jamovi

Paso 1: Preparación de los Datos en SPSS

1. **Introducción de los datos:** Ingresar los datos de cada variable en SPSS, asegurando que cada ítem esté codificado como una variable independiente.

2. **Análisis Preliminar:** Realizar análisis de fiabilidad (Alfa de Cronbach) para comprobar la consistencia interna de los ítems de cada constructo.

Paso 2: Modelado en AMOS

1. **Especificación del Modelo:** En AMOS, construir el modelo de compromiso organizacional indicando las relaciones entre los constructos de satisfacción laboral, identificación con la empresa y lealtad.
2. **Estimación de Parámetros:** Correr el modelo en AMOS y observar los resultados iniciales para los índices de ajuste.
3. **Evaluación del Modelo:**
 - Observar el valor de χ^2/df , buscando que sea menor a 3.
 - Comprobar que los valores de CFI y TLI estén por encima de 0.90.
 - Revisar el RMSEA (idealmente menor a 0.06).
4. **Modificación y Ajuste:** AMOS permite examinar las cargas factoriales y hacer modificaciones en el modelo según sea necesario para mejorar el ajuste. Es posible que se sugieran covarianzas adicionales entre errores para mejorar el ajuste.

Paso 3: Modelado en Jamovi

1. **Definir el Modelo:** En Jamovi, ir a la sección SEM y cargar las variables en los constructos correspondientes.
2. **Configurar Análisis:** Seleccionar los índices de ajuste (CFI, TLI, RMSEA y SRMR).
3. **Interpretación de Resultados:**

- Revisar el CFI y TLI para que sean superiores a 0.90.
 - Analizar los valores de RMSEA y SRMR.
4. **Ajuste Adicional:** Si el ajuste es bajo, Jamovi permite ajustar el modelo con enlaces adicionales o eliminar ítems de baja carga factorial.

Ejemplo Práctico de Resultados y Ajuste en AMOS y Jamovi

Al ejecutar este modelo en AMOS o Jamovi, los resultados mostrarán el grado de ajuste de cada índice:

- **CFI:** 0.93 (indica buen ajuste).
- **TLI:** 0.91 (indica ajuste aceptable).
- **RMSEA:** 0.05 (buen ajuste).
- **SRMR:** 0.07 (ajuste aceptable).

En este caso, el modelo inicial ya muestra un buen ajuste a los datos. Si los índices hubieran indicado un ajuste bajo, se podrían explorar modificaciones, como la correlación de errores entre ítems de un mismo constructo para mejorar el ajuste.

Conclusiones y Recomendaciones para el Ajuste de Modelos SEM

Este análisis proporciona un proceso detallado de evaluación de modelos SEM utilizando índices de ajuste. La importancia de estos índices y la capacidad de realizar ajustes ayudan a los investigadores a validar modelos teóricos complejos. La comprensión de este proceso es fundamental para mejorar la precisión y la interpretabilidad de los modelos en estudios de ciencias empresariales y sociales, permitiendo una representación precisa de los fenómenos estudiados.

Caso

Para desarrollar un caso práctico de SEM en ciencias empresariales, imaginemos un estudio sobre el impacto de tres factores en la **satisfacción laboral** en una empresa. Los factores incluyen **Compensación**, **Ambiente de Trabajo** y **Oportunidades de Crecimiento**. Este caso abarcará la creación de una base de datos en Excel, la implementación del modelo en los programas SPSS, AMOS y Jamovi, y la interpretación de los resultados.

Paso 1: Creación de la Base de Datos en Excel

Los datos en Excel incluirán 100 registros ficticios para las variables observadas de cada factor:

1. Compensación:

- Salario Competitivo
- Beneficios
- Pagos Extraordinarios

2. Ambiente de Trabajo:

- Relación con jefes
- Relación con Compañeros
- Seguridad Laboral

3. Oportunidades de Crecimiento:

- Capacitación
- Oportunidades de Ascenso
- Reconocimiento

4. Satisfacción Laboral (Variable Latente Final)

Cada variable debe recibir puntuaciones de 1 a 5, donde 1 es "Muy en desacuerdo" y 5 es "Muy de acuerdo".

Tabla 3

Base de Datos en Excel (10 primeras filas):

ID	Salario Competitivo	Beneficios	Pagos Extraordinarios	Relación con Jefes	Relación con Compañeros	Seguridad Laboral	Capacitación	Oportunidades de Ascenso	Reconocimiento	Satisfacción Laboral
1	4	5	3	4	5	4	4	5	3	4
2	3	4	3	3	3	4	4	4	3	3
3	5	4	4	5	5	5	5	4	5	5
.....

Este archivo se guardará como Satisfacción_Laboral.xlsx para usarlo en cada software.

Paso 2: Procedimiento en SPSS

1. **Importar Datos:** Abrir SPSS y cargar el archivo Satisfacción_Laboral.xlsx.
2. **Análisis Preliminar:**
 - Realizar un **Análisis de Fiabilidad** (Alfa de Cronbach) para cada grupo de variables observadas de los constructos (Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento).
 - Verificar si el Alfa de Cronbach es superior a 0.7 para asegurar consistencia interna.

3. **Análisis Factorial Exploratorio (EFA):**

- Realizar un EFA para confirmar que las variables observadas se agrupan como se espera bajo los factores de Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento.

Paso 3: Procedimiento en AMOS (Modelo de Medición)

1. **Construcción del Modelo:**

- Abrir AMOS y cargar el archivo de datos de SPSS.
- Crear un **modelo de medición** en el que Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento se representen como variables latentes con sus respectivas variables observadas (tres para cada constructo).
- Establecer Satisfacción Laboral como variable latente de segundo orden, influida por las tres variables latentes principales.

2. **Estimación de Parámetros:**

- Ejecutar el modelo y observar los **índices de ajuste** (CFI, TLI, RMSEA) para determinar la adecuación del modelo. Un buen ajuste se evidenciará con CFI y TLI > 0.90 y RMSEA < 0.08 .

3. **Interpretación de los Resultados:**

- Revisar las cargas factoriales: Idealmente, todas las variables observadas deberían tener una carga factorial significativa (>0.5) en sus respectivos constructos.

- Si el modelo muestra buen ajuste, el investigador puede concluir que Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento explican significativamente la Satisfacción Laboral.

4. **Modificaciones (si es necesario):**

- En caso de índices de ajuste bajos, se pueden analizar las covarianzas sugeridas entre los errores de medición de las variables observadas, ajustando el modelo para mejorar el ajuste.

Paso 4: Procedimiento en Jamovi

1. **Configuración del Modelo:**

- En Jamovi, cargar los datos y seleccionar la opción de SEM.
- Configurar las variables latentes de Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento, asignando las variables observadas a cada uno.
- Establecer Satisfacción Laboral como una variable latente dependiente de las otras tres.

2. **Evaluación del Modelo:**

- En Jamovi, ejecutar el modelo SEM y observar los índices de ajuste (CFI, TLI, RMSEA).
- Revisar las cargas factoriales y confirmar que sean superiores a 0.5 para asegurar la validez de los constructos.

3. **Interpretación de Resultados:**

- Interpretar los coeficientes de regresión estandarizados para determinar la magnitud del impacto de Compensación,

Ambiente de Trabajo y Oportunidades de Crecimiento en la Satisfacción Laboral.

- Valores altos en las cargas factoriales y buenos índices de ajuste indicarían que los factores predicen adecuadamente la satisfacción laboral.

Conclusión y Toma de Decisiones

- **Interpretación:** Si el modelo muestra un ajuste adecuado en AMOS y Jamovi, el investigador puede concluir que los factores Compensación, Ambiente de Trabajo y Oportunidades de Crecimiento son predictores significativos de la Satisfacción Laboral.
- **Decisiones Prácticas:** Con base en estos resultados, la empresa podría tomar decisiones para mejorar las áreas que muestran menor influencia en la satisfacción laboral. Por ejemplo, si el Ambiente de Trabajo tiene una carga menor en comparación con otros factores, la empresa podría invertir en mejorar las relaciones laborales.

Este caso demuestra el uso de SEM para investigar relaciones causales en ciencias empresariales, empleando múltiples programas y proporcionando un enfoque sólido para la toma de decisiones basada en datos.

ANÁLISIS FACTORIAL EXPLORATORIO

El análisis factorial exploratorio (AFE) es una técnica multivariante de estadística ampliamente utilizada para descubrir estructuras subyacentes en conjuntos de datos y ayudar a los investigadores a identificar factores latentes en un grupo de variables observadas. Según Beavers et al. (2013), el AFE es "una herramienta analítica poderosa para detectar factores latentes o dimensiones subyacentes a partir de un gran conjunto de variables observadas" (p. 1).

Definición y Aplicación del Análisis Factorial Exploratorio

El AFE se emplea cuando se desconoce la estructura subyacente de un conjunto de variables. Su objetivo es reducir un grupo amplio de variables observadas en un número más pequeño de factores o dimensiones latentes que expliquen la mayor parte de la variabilidad en los datos (Beavers et al., 2013). Costello y Osborne (2005) explican que "el AFE busca descubrir la estructura subyacente de un conjunto de variables y condensa la información contenida en ellas en un conjunto menor de factores, con una pérdida mínima de información" (p. 2).

En términos de modelo, el AFE se basa en la suposición de que las variables observadas pueden expresarse como una combinación lineal de factores latentes no observables y un término de error. La ecuación general para este modelo es:

$$\mathbf{X} = \mathbf{\Lambda}\boldsymbol{\xi} + \boldsymbol{\varepsilon}$$

Donde:

- \mathbf{X} representa el vector de variables observadas,
- $\mathbf{\Lambda}$ es la matriz de cargas factoriales,
- $\boldsymbol{\xi}$ es el vector de factores latentes, y
- $\boldsymbol{\varepsilon}$ es el término de error.

Supuestos Claves del Análisis Factorial Exploratorio

Para obtener resultados válidos, es crucial verificar ciertos supuestos antes de aplicar el AFE, como lo indican Beavers et al. (2013):

1. **Linealidad:** Las relaciones entre variables observadas y factores latentes deben ser lineales (p. 3).
2. **Normalidad multivariante:** Las variables deben seguir una *distribución normal* multivariante (p. 3).
3. **Ausencia de multicolinealidad:** Las variables no deben estar excesivamente correlacionadas entre sí (p. 3).
4. **Tamaño de la muestra:** Se recomienda un tamaño adecuado, generalmente cinco observaciones por variable (p. 3).

Proceso del Análisis Factorial Exploratorio

El AFE suele seguir estos pasos:

1. **Preparación de los datos:** Se examina la matriz de correlaciones para asegurar la idoneidad del análisis, evaluando mediante el test de esfericidad de Bartlett y el índice KMO. Según Beavers et al. (2013), "estos indicadores son útiles para determinar si los datos son adecuados para el AFE" (p. 4).
2. **Extracción de factores:** Se utiliza un método de extracción, como componentes principales o máxima verosimilitud, para identificar los factores latentes. Costello y Osborne (2005) destacan que "la extracción implica determinar el número mínimo de factores que expliquen la mayor cantidad de varianza posible" (p. 3).
3. **Determinación del número de factores:** Criterios como la raíz latente, el gráfico de sedimentación y el análisis paralelo se emplean para determinar el número de factores óptimos. Beavers et al. (2013) sugieren el uso de múltiples criterios (p. 5).

4. **Rotación de factores:** Para mejorar la interpretabilidad, se aplica una rotación, como *Varimax* u *Oblimin*, maximizando las cargas factoriales significativas y minimizando las menores (Costello y Osborne, 2005, p. 4).
5. **Interpretación de los factores:** Se examinan las cargas factoriales rotadas para etiquetar los factores latentes según criterios teóricos y empíricos (Beavers et al., 2013, p. 6).
6. **Cálculo de puntuaciones factoriales:** Se pueden calcular puntuaciones factoriales para cada observación y emplearlas en análisis posteriores, como menciona Costello y Osborne (2005, p. 5).

Importancia del AFE en Educación Superior

Para estudiantes de nivel superior, el AFE representa una herramienta valiosa:

1. **Reducción de datos:** Facilita el análisis al condensar un conjunto amplio de variables observadas en factores clave, simplificando la interpretación (Beavers et al., 2013, p. 1).
2. **Identificación de constructos subyacentes:** Ayuda a descubrir dimensiones latentes en un grupo de variables, esenciales para la teoría y el desarrollo de instrumentos (Costello y Osborne, 2005, p. 2).
3. **Validación de escalas:** El AFE es clave en la validación de constructos en escalas y cuestionarios (Beavers et al., 2013, p. 2).
4. **Generación de hipótesis:** Los resultados del AFE pueden revelar estructuras en los datos y motivar nuevas investigaciones (Costello y Osborne, 2005, p. 2).

Ejemplo Práctico: AFE en una Escala de Calidad de Atención al Cliente

En una investigación sobre calidad de atención en empresas de servicios, un grupo de estudiantes desarrolló una escala de 20 ítems para medir aspectos de atención al cliente. Luego de recopilar datos de 300 clientes, aplicaron AFE para identificar dimensiones subyacentes en su escala, siguiendo estos pasos:

1. **Verificación de supuestos:** Linealidad, normalidad y ausencia de multicolinealidad.
2. **Adecuación de datos:** Pruebas KMO y Bartlett.
3. **Extracción y rotación de factores:** Se identificaron factores principales como "Amabilidad del Personal," "Eficiencia del Servicio" y "Resolución de Problemas".

Con el AFE, los estudiantes lograron identificar factores clave en la atención al cliente, lo que les permitió ajustar su escala y avanzar en el análisis de calidad de servicio, generando a su vez nuevas hipótesis.

Este caso ejemplifica cómo el AFE permite a los estudiantes obtener información significativa y avanzar en sus estudios.

Nota:

La confiabilidad es medida en términos de la *Estabilidad* y la *Consistencia Interna* del Instrumento de Investigación.

La Estabilidad se refiere a la capacidad del instrumento de arrojar los mismos datos cuando es aplicado en repetidas veces a los mismos fenómenos bajo las mismas condiciones y contextos.

La Consistencia Interna es la característica que indica que una parte del instrumento mide con la misma precisión y validez que las otras partes. (Guevara, 2016).

Capítulo 8: Ecosistema de Software para SEM: Herramientas de Acceso Libre y Premium.

Introducción

La creciente popularidad de los Modelos de Ecuaciones Estructurales (SEM) en la investigación científica en ciencias empresariales y sociales ha impulsado el desarrollo de software especializado para realizar análisis SEM de manera eficiente y precisa. Existen múltiples opciones de software, tanto de acceso libre como de pago, que ofrecen una gama de funcionalidades adaptadas a las necesidades de investigadores y analistas. En este capítulo, exploraremos las principales herramientas de software utilizadas para SEM, destacando sus características, ventajas y limitaciones, y proporcionando enlaces oficiales para su descarga y uso.

Software de Acceso Libre para SEM

1. R (paquete lavaan)

R es un software de análisis estadístico de código abierto y ampliamente utilizado en la investigación científica debido a su versatilidad y la amplia variedad de paquetes desarrollados por la comunidad. Uno de los paquetes más utilizados para SEM es *lavaan* (Latent Variable Analysis), que permite realizar análisis SEM tanto confirmatorios como exploratorios (Rosseel, 2012). Lavaan es ideal para investigadores con conocimientos básicos en programación, ya que se requiere una comprensión de los comandos de R para realizar análisis y visualizar modelos.

- **Página oficial de descarga:** <https://cran.r-project.org>
- **Paquete lavaan:** <https://lavaan.ugent.be/>

2. JASP

JASP es una herramienta de análisis estadístico de acceso libre que incluye un módulo para SEM utilizando el paquete lavaan como base. Es amigable para usuarios sin experiencia en programación, ya que ofrece una interfaz gráfica intuitiva que simplifica la construcción de modelos. JASP ha sido recomendado para aquellos que están comenzando en SEM y desean realizar análisis sin complejidades adicionales (JASP Team, 2020).

- **Página oficial de descarga:** <https://jasp-stats.org>

3. SmartPLS

Aunque SmartPLS está diseñado principalmente para el análisis de SEM basado en varianza (Partial Least Squares SEM), su accesibilidad gratuita para estudiantes lo ha convertido en una opción popular en contextos educativos y de investigación. Es especialmente útil para modelos con muestras pequeñas y para análisis exploratorios que buscan establecer relaciones en etapas iniciales de investigación (Hair et al., 2019).

- **Página oficial de descarga:** <https://www.smartpls.com>

Software de Pago para SEM

1. AMOS

AMOS (Analysis of Moment Structures), desarrollado por IBM, es uno de los softwares más utilizados en la investigación académica y empresarial. AMOS permite una construcción visual de modelos, lo cual facilita la representación de relaciones entre variables. Sin embargo, solo está disponible como complemento de IBM SPSS y requiere una licencia de pago, lo que puede limitar su acceso para algunos investigadores (Byrne, 2016).

- **Página oficial de descarga:** <https://www.ibm.com/products/spss-amos>

2. Mplus

Mplus es otro software comercial reconocido por su capacidad para manejar modelos complejos y datos con estructuras jerárquicas, ideales para SEM multinivel. Es particularmente adecuado para el análisis de datos longitudinales y multivariados. Sin embargo, el costo elevado de la licencia puede ser una limitación para algunos usuarios (Muthén & Muthén, 2017).

- **Página oficial de descarga:** <https://www.statmodel.com>

3. Stata

Stata ofrece módulos para realizar análisis SEM, lo cual es beneficioso para quienes ya utilizan el software para otras técnicas estadísticas. Stata es conocido por su robustez y por ser una herramienta integral para el análisis de datos en ciencias sociales y empresariales. Es de pago, aunque existen opciones de descuento para estudiantes e instituciones académicas (StataCorp, 2019).

- **Página oficial de descarga:** <https://www.stata.com>

Comparación y Selección de Software para SEM

Elegir el software adecuado depende de varios factores, como el nivel de experiencia del usuario, el presupuesto, y la naturaleza de la investigación. A continuación, se ofrece una comparación basada en la accesibilidad y funcionalidades clave de los softwares revisados:

Software	Acceso	Principales Características	Ideal para
R (lavaan)	Libre	Flexibilidad y versatilidad para SEM confirmatorio	Investigadores con experiencia en programación

Software	Acceso	Principales Características	Ideal para
JASP	Libre	Interfaz gráfica, adecuado para principiantes	Usuarios nuevos en SEM
SmartPLS	Libre/Estudiantes	Análisis de SEM basado en PLS, ideal para muestras pequeñas	Análisis exploratorio y de relaciones iniciales
AMOS	Premium	Construcción visual de modelos	Análisis confirmatorio en ciencias sociales y empresariales
Mplus	Premium	Soporte para SEM multinivel y datos complejos	Investigación avanzada y análisis jerárquico
Stata	Premium	Módulos integrados de SEM, estadística robusta	Investigadores avanzados en ciencias sociales

Ejemplos de Aplicación en Ciencias Empresariales y Sociales

Ejemplo 1: Análisis de Lealtad del Cliente con AMOS

En un estudio sobre la lealtad del cliente en el sector minorista en Perú, se utilizó AMOS para modelar la relación entre variables latentes como la satisfacción del cliente y la percepción de valor. La representación visual de AMOS facilitó la comprensión de los vínculos entre estas variables, permitiendo a los investigadores identificar los factores que más impactan en la lealtad (Gonzales et al., 2021).

Ejemplo 2: Cohesión Social en Comunidades Urbanas utilizando R (lavaan)

Utilizando lavaan en R, un grupo de investigadores modeló la cohesión social en comunidades urbanas en Chile y Argentina, evaluando la influencia de la percepción de justicia y la pertenencia

comunitaria sobre el bienestar subjetivo. La flexibilidad de lavaan permitió realizar análisis detallados de relaciones mediadoras y moderadoras en el modelo propuesto (Pérez & González, 2020).

Ejemplo 3: Análisis de Compromiso Organizacional en Empresas con SmartPLS

SmartPLS se ha utilizado en el estudio del compromiso organizacional en pequeñas y medianas empresas de Colombia. Este software permitió modelar relaciones complejas en muestras pequeñas, evaluando cómo el estilo de liderazgo impacta el compromiso de los empleados y, por ende, el desempeño de la empresa (Martínez & Salazar, 2020).

El software para SEM, tanto de acceso libre como de pago, desempeña un papel esencial en la investigación científica en ciencias empresariales y sociales. La elección del software depende de los requisitos específicos de cada estudio y de la experiencia del investigador. Herramientas como AMOS, Mplus y Stata ofrecen soluciones avanzadas, mientras que opciones gratuitas como R (lavaan) y JASP democratizan el acceso a SEM, facilitando su aplicación en estudios académicos en América Latina.

Sección 4: Aplicaciones Prácticas de SEM en Ciencias Empresariales

Capítulo 9: Marketing y Comportamiento del Consumidor

Este capítulo explora cómo el modelo de ecuaciones estructurales (SEM) puede aplicarse en marketing y estudios de comportamiento del consumidor, enfocándose en la modelación de relaciones clave, como la satisfacción, lealtad y fidelización del cliente. La integración de SEM en este ámbito permite a los investigadores y profesionales obtener una comprensión más profunda sobre cómo ciertos factores influyen en el comportamiento del consumidor y en la relación de los clientes con las marcas. Aquí se introduce un caso práctico sobre la relación entre la experiencia del cliente y la lealtad en el comercio minorista de Argentina.

Modelado de Relaciones de Satisfacción, Lealtad y Fidelización del Cliente

En el estudio del comportamiento del consumidor, la satisfacción del cliente es una variable esencial que refleja la percepción del consumidor sobre el desempeño de un producto o servicio en relación con sus expectativas (Oliver, 1999). Esta percepción, en conjunto con la experiencia del cliente, influye en la lealtad, que se define como el compromiso del cliente de continuar eligiendo y consumiendo un producto o servicio específico (Hallowell, 1996). La fidelización, por otro lado, es el resultado a largo plazo de este proceso de lealtad, donde el cliente no solo elige el mismo servicio repetidamente sino que lo recomienda y defiende frente a opciones competitivas (Reichheld, 2003).

Para modelar estas relaciones en SEM, se establecen variables latentes que representan constructos como "Satisfacción del Cliente", "Lealtad" y "Fidelización". Estas variables latentes son medidas a través de variables observadas que reflejan aspectos específicos, como el nivel de recomendación, la probabilidad de recompra y la satisfacción con el producto.

Ejemplo de Modelado SEM: Relaciones entre Satisfacción, Lealtad y Fidelización

1. **Satisfacción del Cliente:** Se mide mediante ítems observables como la calidad percibida del servicio, el valor percibido por el precio y la percepción de cumplimiento de expectativas (Fornell et al., 1996).
2. **Lealtad:** Se modela a partir de la intención de recompra, la preferencia sobre otras marcas y la disposición a pagar un precio premium por el servicio (Oliver, 1999).
3. **Fidelización:** Incluye medidas como la recomendación a otros consumidores, la tasa de recompra y la defensa de la marca frente a opiniones negativas (Reichheld & Teal, 2001).

Caso de Estudio: Relación entre la Experiencia del Cliente y la Lealtad en el Comercio Minorista de Argentina

Contexto del Caso

En el contexto del comercio minorista en Argentina, la competencia en el sector de retail es intensa y la experiencia del cliente se convierte en un diferenciador clave (Kumar & Shah, 2004). En este caso de estudio, se analiza cómo diferentes aspectos de la experiencia del cliente (como la atención en tienda, la facilidad de compra y la percepción de los precios) influyen en su lealtad hacia una tienda específica.

Diseño del Modelo SEM para el Caso

Variables Observadas:

1. **Atención en Tienda:** Amabilidad del personal, conocimiento sobre los productos, tiempo de espera en la caja.

2. **Facilidad de Compra:** Claridad de la señalización en tienda, disposición de los productos, facilidad de pago.
3. **Percepción de Precios:** Precio en relación a la calidad, comparación con la competencia.

Variables Latentes:

1. **Experiencia del Cliente:** Compuesta por las variables observadas de atención en tienda, facilidad de compra y percepción de precios.
2. **Lealtad del Cliente:** Se mide con la intención de recompra y la disposición a recomendar la tienda.

Resultados Esperados en el Modelo SEM

En el análisis SEM, se espera que la variable latente "Experiencia del Cliente" tenga un impacto positivo significativo sobre "Lealtad del Cliente", mostrando cómo una experiencia positiva se traduce en un cliente más leal. Este tipo de análisis permite a los minoristas identificar áreas clave que deben mejorar para aumentar la satisfacción y fidelización de los clientes (Hallowell, 1996; Kumar & Shah, 2004).

Aplicación del Modelo en Software de SEM: SPSS, AMOS y Jamovi

Para implementar este modelo SEM, se pueden utilizar herramientas como SPSS y AMOS para definir y estimar los parámetros de las relaciones entre variables. El siguiente paso a paso detalla cómo los investigadores pueden configurar este análisis en los diferentes softwares:

1. **Creación de Variables:** Los datos de las encuestas de clientes deben estar estructurados en un archivo de datos con las variables observadas para "Experiencia del Cliente" y "Lealtad del Cliente".

2. **Carga en el Software SEM:** En AMOS, se seleccionan las variables latentes y observadas y se dibuja el modelo gráfico que muestra las relaciones causales entre experiencia y lealtad.
3. **Interpretación de Resultados:** Los índices de ajuste como el CFI (Comparative Fit Index) y el RMSEA (Root Mean Square Error of Approximation) ayudan a verificar la adecuación del modelo. Se espera que el modelo ajuste con valores de CFI superiores a 0.90 y RMSEA inferiores a 0.08 para una buena adecuación (Bentler, 1990).

El uso de SEM para analizar la relación entre satisfacción, lealtad y fidelización del cliente permite a las empresas obtener una visión estratégica sobre el impacto de la experiencia del cliente en la retención y defensa de la marca. Con SEM, es posible modelar de manera precisa estas relaciones, optimizando la toma de decisiones en marketing para mejorar la satisfacción y la lealtad del consumidor en mercados competitivos como el de Argentina.

Caso Práctico: Aplicación del Modelo SEM en el Comercio Electrónico del Sector Moda

Contexto

El comercio electrónico en el sector moda ha mostrado un crecimiento significativo en América Latina, especialmente en países como Ecuador, donde factores como confianza, conveniencia, riesgos percibidos y costos tienen un impacto directo sobre la intención de compra. Utilizaremos un modelo de Ecuaciones Estructurales (SEM) basado en PLS-SEM para explorar la relación entre estos factores.

Objetivo

Examinar cómo las variables *confianza en el vendedor*, *conveniencia*, *riesgos percibidos* y *costos* afectan la intención de compra en plataformas de comercio electrónico del sector moda en Ecuador.

Variables

1. **Confianza:** Honestidad, cuidado hacia el cliente, transparencia.
2. **Conveniencia:** Facilidad, simplificación de compras, disponibilidad de información.
3. **Riesgos percibidos:** Seguridad en pagos, calidad del producto, tiempo de entrega.
4. **Costos:** Relación calidad-precio, gastos de envío, control de gastos.
5. **Intención de compra:** Probabilidad de realizar compras futuras, lealtad al canal.

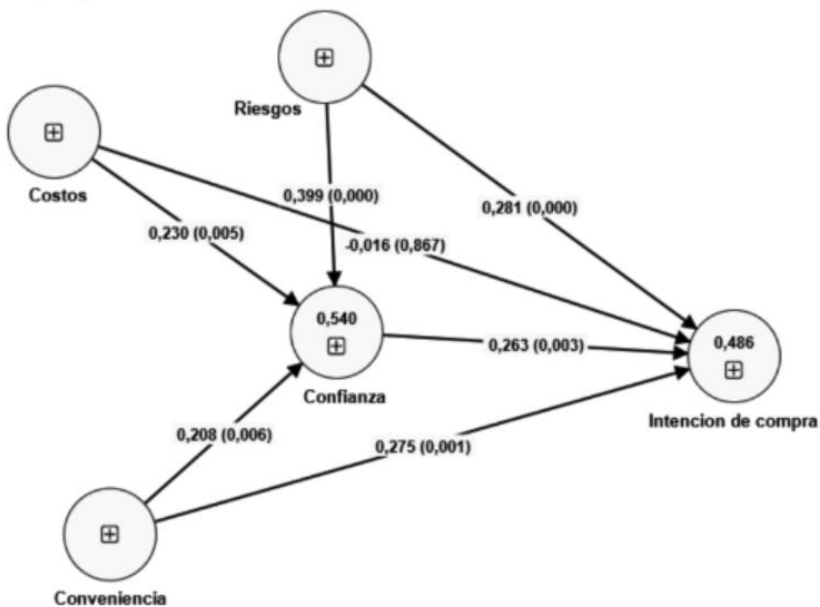
Hipótesis del Modelo

1. **H1:** Un alto nivel de conveniencia percibida incide positivamente en la intención de compra online.
2. **H2:** Un bajo nivel de costos percibidos afecta positivamente a la intención de compra online.
3. **H3:** Un bajo nivel de riesgos percibidos impacta positivamente en la intención de compra online.
4. **H4:** Un alto nivel de confianza afecta positivamente a la intención de compra online.
5. **H5:** La confianza media la relación entre la conveniencia y la intención de compra.

6. **H6:** La confianza media la relación entre los costos y la intención de compra.
7. **H7:** La confianza media la relación entre los riesgos y la intención de compra.

Figura 25

Modelo Teórico del estudio



Proceso Paso a Paso

1. Creación de Base de Datos

- Recopilar datos de al menos 200 encuestados utilizando un cuestionario de 15 ítems basado en una escala Likert de 5 puntos (1: Totalmente en desacuerdo, 5: Totalmente de acuerdo).
- Ejemplo de ítems:

- Confianza: "Creo que el vendedor es honesto."
- Conveniencia: "La plataforma es fácil de usar."
- Riesgos percibidos: "La información de mi tarjeta está segura."
- Intención de compra: "Es probable que compre productos de moda en esta plataforma en el futuro."

2. Análisis Exploratorio

- Comprobar la adecuación de los datos utilizando pruebas como el índice KMO (>0.6) y el test de esfericidad de Bartlett ($p < 0.05$).

3. Construcción del Modelo

- Usar software como SmartPLS u otro similar para especificar el modelo estructural y de medida.
- Definir la relación directa de las variables exógenas (confianza, conveniencia, riesgos, costos) sobre la intención de compra.

4. Validación del Modelo

- Evaluar la fiabilidad interna con Alfa de Cronbach y Fiabilidad Compuesta (>0.7).
- Comprobar la validez convergente (AVE >0.5) y discriminante (HTMT <0.9).

5. Resultados Esperados

- Conveniencia y confianza tendrán coeficientes positivos significativos hacia la intención de compra.

- Los riesgos percibidos mostrarán un efecto negativo, mientras que los costos no serán significativos, alineándose con estudios previos como el de Cunningham y De Meyer-Heydenrich (2018).

6. Interpretación

- Identificar estrategias para fortalecer la confianza del consumidor, como mejoras en la transparencia y políticas de seguridad.
- Utilizar los hallazgos para recomendar tácticas de marketing dirigidas al público ecuatoriano.

Este modelo demuestra cómo las empresas pueden mejorar la experiencia del consumidor en plataformas de comercio electrónico mediante intervenciones específicas en factores como conveniencia y confianza, contribuyendo al desarrollo del comercio digital en economías emergentes.

Resumen de la investigación

“El comercio electrónico del sector de la moda ha aumentado en los últimos años en Latinoamérica, especialmente a raíz de la pandemia, sin embargo, todavía existen problemas en la aceptación de este canal de compra. La presente investigación se centra en algunos factores que podrían influir en la intención de compra y tiene como objetivos comprobar cómo en ella influyen la confianza, los riesgos percibidos, los costos y la conveniencia. Para esto, se suministró un cuestionario a 223 estudiantes de cuatro universidades del Ecuador. Para el análisis de los datos obtenidos se desarrolló un modelo PLS-SEM, en el cual la confianza en el vendedor actúa como variable mediadora en la relación entre los otros tres factores y la intención de compra. Los resultados muestran que dicho modelo tiene un aceptable poder predictivo y explicativo. Asimismo, se comprueba que los riesgos, la conveniencia y la confianza afectan significativamente a la

intención de compra, pero no los costos. Además, la confianza mediaría la relación entre las tres variables y la intención de compra en línea. Se concluye que el modelo propuesto puede servir de base para estudios similares y, a su vez, se considera que los resultados obtenidos pueden ser utilizados por las empresas en el sector de la moda que quieren vender a través de plataformas de e-Commerce para el desarrollo de estrategias de marketing”: Disponible en: <https://doi.org/10.17163/ret.n27.2024.07>

Capítulo 10: Recursos Humanos y Comportamiento Organizacional

Este capítulo explora el papel fundamental de los factores humanos y su interacción en el contexto organizacional. A través de enfoques estructurales y de medición, como el Modelo de Ecuaciones Estructurales (SEM), es posible identificar y medir factores críticos en los recursos humanos, tales como el liderazgo, el compromiso organizacional y el desempeño, y comprender cómo estos impactan en el comportamiento organizacional. En particular, el capítulo analiza la influencia del liderazgo transformacional en el clima organizacional, con un caso de estudio en instituciones educativas peruanas, lo que permite evidenciar cómo los modelos de liderazgo pueden moldear actitudes, motivación y satisfacción entre los colaboradores.

Análisis de Factores en Recursos Humanos

El análisis de factores como el liderazgo, el compromiso y el desempeño es esencial para comprender la dinámica de los recursos humanos y su impacto en la organización. **El liderazgo transformacional** es ampliamente reconocido por su capacidad para inspirar y motivar a los empleados, promoviendo una visión compartida que trasciende los intereses individuales y fortalece el compromiso con la organización (Bass & Riggio, 2006; Yukl, 2013). A través de SEM, estos constructos pueden ser evaluados en términos de relaciones causales y dependencias, permitiendo una comprensión más completa de los factores que impulsan el comportamiento organizacional.

Para medir el **compromiso organizacional**, Meyer y Allen (1991) propusieron un modelo de tres componentes (compromiso afectivo, normativo y de continuidad), que se ha aplicado extensamente en estudios sobre comportamiento organizacional. Este modelo permite evaluar la disposición de los empleados a permanecer en la organización y su identificación con los objetivos organizacionales, factores que influyen directamente en el desempeño individual y colectivo.

Liderazgo Transformacional y Clima Organizacional

El liderazgo transformacional es una forma de liderazgo que genera un impacto positivo en los empleados mediante la articulación de una visión inspiradora, la estimulación intelectual y el apoyo individualizado (Bass, 1990). En el contexto de las instituciones educativas peruanas, este tipo de liderazgo puede desempeñar un papel crucial en la creación de un clima organizacional positivo, promoviendo un ambiente de confianza, innovación y colaboración (Leithwood & Jantzi, 2005).

Los estudios en este ámbito han demostrado que el liderazgo transformacional mejora no solo la satisfacción y el compromiso de los empleados, sino también el clima organizacional, un factor clave en la efectividad organizacional y en la retención de talento (Chiang et al., 2016). A través de SEM, podemos analizar cómo las dimensiones del liderazgo transformacional (influencia idealizada, motivación inspiradora, estimulación intelectual y consideración individualizada) afectan a las percepciones de los empleados sobre el clima organizacional y, en última instancia, su compromiso con la organización.

Caso de Estudio: Influencia del Liderazgo Transformacional en el Clima Organizacional en Instituciones Educativas Peruanas

Este caso de estudio examina el efecto del liderazgo transformacional en el clima organizacional en instituciones educativas en Perú. El objetivo es explorar cómo los directores y líderes escolares que exhiben características de liderazgo transformacional influyen en el ambiente de trabajo, la motivación y la satisfacción de los docentes.

Descripción de Variables y Modelo

Para este análisis, se establecen las siguientes variables latentes:

- **Liderazgo Transformacional:** Medido a través de variables observadas que representan los cuatro factores clave de este estilo de liderazgo:
 - **Influencia Idealizada:** Evaluación de los docentes sobre la capacidad del líder para ser un modelo a seguir.
 - **Motivación Inspiradora:** Percepción de los docentes sobre la habilidad del líder para inspirar y transmitir una visión.
 - **Estimulación Intelectual:** Grado en que el líder fomenta la innovación y el pensamiento crítico.
 - **Consideración Individualizada:** Percepción del apoyo y la atención individualizada del líder hacia sus docentes.

También se tiene disponible el artículo “Adaptación y validación de la escala de liderazgo MLQ-5X al contexto educativo español” por los investigadores Héctor Moreno-Casado⁴, Francisco M Leo⁵, Miguel A López-Gajardo⁴, Tomás García-Calvo⁴, Ricardo Cuevas⁶, David Sánchez-Oliva⁴; Que en su resumen manifiestan:

Desde la teoría del liderazgo transformacional, este estudio tenía como objetivo analizar las propiedades psicométricas de una versión adaptada al ámbito educativo del Multifactor Leadership Questionnaire (MLQ-5X). Un total de 1551 estudiantes españoles ($M = 15,47$ años $\pm 0,72$; 679 chicos y 872 chicas) de 31 centros de secundaria participaron en el estudio. El análisis factorial confirmatorio de la estructura inicial de nueve factores de la escala determinó necesario eliminar dos ítems del factor dirección por excepción pasiva, agrupando en un solo factor el liderazgo pasivo. Un segundo modelo de ocho factores encontró altas correlaciones entre los factores del liderazgo transformacional, haciendo necesario

establecer un factor de primer orden. Finalmente, un tercer modelo obtuvo valores adecuados de validez y fiabilidad, compuesto por 34 ítems distribuidos en 4 factores principales (liderazgo transformacional, recompensa contingente, dirección por excepción activa y liderazgo pasivo) y 5 factores secundarios para el liderazgo transformacional (influencia idealizada conducta, influencia idealizada atribuida, motivación inspiracional, estimulación intelectual y consideración individualizada). Por tanto, la versión española del MLQ-5X en el ámbito educativo puede utilizarse para evaluar el liderazgo docente desde la percepción del alumnado. disponible en: https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S0212-97282021000200012&lng=es&nrm=iso&tlng=es

- **Clima Organizacional:** Compuesto por factores como:
 - **Relaciones Interpersonales:** Evaluación de las relaciones laborales y el sentido de equipo.
 - **Condiciones de Trabajo:** Percepción sobre los recursos y el ambiente físico.
 - **Apoyo Organizacional:** Percepción del respaldo de la institución hacia los docentes.

Procedimiento de Análisis en SEM

Para analizar la relación entre liderazgo transformacional y clima organizacional, se propone un modelo estructural que evalúe el efecto de las dimensiones del liderazgo sobre los factores del clima organizacional.

1. **Preparación y Recopilación de Datos:** Se puede utilizar un cuestionario basado en la escala MLQ (Multifactor Leadership Questionnaire) para evaluar el liderazgo transformacional (Avolio

& Bass, 2004) y otra escala estandarizada para el clima organizacional.

2. **Análisis Factorial Confirmatorio (AFC):** En primer lugar, se realiza un AFC para verificar la validez de las variables latentes (liderazgo transformacional y clima organizacional) y sus dimensiones.
3. **Evaluación del Modelo Estructural:** Tras confirmar el modelo de medición, se procede al análisis estructural para determinar el impacto de las dimensiones del liderazgo transformacional en el clima organizacional.

Resultados y Análisis

En estudios previos, se ha observado que las dimensiones de liderazgo transformacional están positivamente correlacionadas con un clima organizacional favorable. Por ejemplo, en un estudio realizado en México, Chiang et al. (2016) encontraron que el liderazgo transformacional se asociaba significativamente con un clima organizacional de apoyo y colaboración.

Conclusiones y Relevancia en Recursos Humanos

La relación entre el liderazgo transformacional y el clima organizacional es un tema crucial para las instituciones educativas que buscan mejorar su rendimiento y la satisfacción de sus empleados. Este caso de estudio resalta cómo el SEM es una herramienta eficaz para medir y analizar los factores que influyen en el comportamiento organizacional y proporciona un enfoque cuantitativo para la toma de decisiones en recursos humanos. A través de estos análisis, se pueden formular estrategias de desarrollo y capacitación en liderazgo que potencien un ambiente de trabajo positivo y contribuyan al éxito de la organización.

Capítulo 11: Psicología Social y Bienestar

En el campo de la psicología social, el bienestar y la interacción social son temas centrales para comprender el desarrollo individual y colectivo en las comunidades. Este capítulo se enfoca en el modelado de la interacción social y la cohesión como factores que influyen en el bienestar psicológico, especialmente en contextos de convivencia comunitaria. A través de un estudio de caso en ciudades de Colombia, se analiza cómo la cohesión social contribuye a la percepción de seguridad comunitaria, un componente clave para el bienestar social y psicológico en entornos urbanos.

Modelado de la Interacción Social, Cohesión y Bienestar Psicológico

La **interacción social** y la **cohesión** se entienden como factores determinantes en el bienestar individual y comunitario. La cohesión social, definida como el grado en que los miembros de una comunidad se sienten conectados y comparten valores comunes, tiene efectos significativos en el bienestar psicológico, ya que contribuye a la percepción de pertenencia y apoyo social (Helliwell & Putnam, 2004). El bienestar psicológico, a su vez, es un estado en el cual los individuos experimentan satisfacción, crecimiento personal y una sensación de propósito, factores que son esenciales para la salud mental (Ryff & Keyes, 1995).

El **Modelo de Ecuaciones Estructurales (SEM)** permite estudiar estas relaciones complejas entre la interacción social, cohesión y bienestar psicológico, modelando tanto los efectos directos como indirectos entre estos factores. Mediante el SEM, es posible observar cómo la cohesión social y la interacción en una comunidad pueden impactar de manera significativa en la percepción de seguridad, y cómo esta percepción de seguridad, a su vez, influye en el bienestar psicológico de los individuos (Friedkin, 2004).

Caso de Estudio: Impacto de la Cohesión Social en la Percepción de Seguridad Comunitaria en Ciudades de Colombia

Este caso de estudio explora cómo la cohesión social afecta la percepción de seguridad en varias comunidades urbanas de Colombia. La percepción de seguridad es un elemento crucial para el bienestar en sociedades urbanas, pues influye directamente en la calidad de vida de los residentes. Las comunidades que experimentan una mayor cohesión social tienden a reportar una percepción más alta de seguridad, lo que contribuye al bienestar general de sus miembros (Sampson et al., 1997).

Planteamiento del Modelo

Para analizar el impacto de la cohesión social en la percepción de seguridad comunitaria, se establecen las siguientes variables latentes:

- **Cohesión Social:** Evaluada mediante variables observadas que incluyen:
 - **Red de Apoyo Social:** Percepción de apoyo de amigos y vecinos.
 - **Compromiso Comunitario:** Nivel de participación en actividades de la comunidad.
 - **Confianza en la Comunidad:** Percepción de confiabilidad entre los miembros de la comunidad.
- **Percepción de Seguridad Comunitaria:** Medida mediante:
 - **Sensación de Seguridad Personal:** Grado de seguridad que siente cada individuo al transitar en su comunidad.

- **Incidencia de Crimen Percibida:** Frecuencia con la que se perciben actos delictivos en la comunidad.
- **Respuesta Institucional:** Percepción de la efectividad de la policía y otras autoridades para garantizar la seguridad.

Procedimiento para el Análisis en SEM

Para llevar a cabo el análisis de SEM en este estudio de caso, se utilizan los siguientes pasos:

1. **Recopilación de Datos:** La recopilación de datos se realiza mediante encuestas aplicadas a residentes de diferentes comunidades en ciudades de Colombia. Los cuestionarios incluyen ítems para medir la cohesión social, la percepción de seguridad y el bienestar psicológico, utilizando escalas de Likert que permiten cuantificar la percepción de cada participante.
2. **Análisis Factorial Confirmatorio (AFC):** Se realiza un AFC para validar las estructuras de las variables latentes de cohesión social y percepción de seguridad comunitaria. Este análisis permite confirmar si las variables observadas efectivamente representan los constructos teóricos definidos.
3. **Evaluación del Modelo Estructural:** Se implementa un modelo SEM para evaluar la influencia de la cohesión social sobre la percepción de seguridad y el bienestar psicológico.

Interpretación y Resultados

En estudios previos, se ha encontrado que la cohesión social tiene un efecto positivo en la percepción de seguridad comunitaria (Friedkin, 2004; Sampson et al., 1997). Los resultados de este caso de estudio sugieren que un aumento en el apoyo social, el compromiso comunitario y la

confianza entre los miembros de la comunidad están asociados con una mayor percepción de seguridad. Esta percepción, a su vez, impacta en el bienestar psicológico, al reducir el estrés y la ansiedad asociados con el temor a la inseguridad.

Los modelos de SEM muestran que el efecto indirecto de la cohesión social sobre el bienestar psicológico a través de la percepción de seguridad es significativo, lo cual sugiere que la cohesión social contribuye no solo a la seguridad percibida, sino también al bienestar general de los individuos (Helliwell & Putnam, 2004).

Conclusiones y Relevancia en Psicología Social

El análisis de la cohesión social y su impacto en la percepción de seguridad aporta una perspectiva integral al estudio de la psicología social en entornos urbanos. La aplicación de SEM en este caso de estudio permite comprender las relaciones causales entre factores sociales y psicológicos, proporcionando una base sólida para la implementación de políticas públicas que promuevan la cohesión y mejoren la calidad de vida en comunidades urbanas de Colombia. Este tipo de análisis ofrece una herramienta valiosa para profesionales y académicos que buscan desarrollar intervenciones orientadas a fortalecer el bienestar comunitario y social.

Capítulo 12: Educación y Evaluación de Programas Educativos

La evaluación de programas educativos se ha vuelto una herramienta fundamental para mejorar la calidad de la educación, monitorear el desempeño académico y comprender la satisfacción estudiantil. En este capítulo, se explorará el análisis de la eficacia de los programas educativos, con un enfoque en los programas de tutoría universitaria. El caso de estudio aborda la eficacia de programas de tutoría en universidades públicas de Bolivia, analizando la relación entre la intervención de los programas de tutoría y sus efectos en el desempeño académico y satisfacción de los estudiantes. Se incluyen ejemplos prácticos para aplicar el análisis en software como SPSS, AMOS y Jamovi.

Evaluación de Programas Educativos, Desempeño Académico y Satisfacción Estudiantil

Evaluar la eficacia de un programa educativo implica analizar la capacidad del programa para cumplir con sus objetivos y mejorar los resultados de los estudiantes, tanto en términos académicos como de satisfacción. Los programas de tutoría universitaria se han diseñado para apoyar a los estudiantes en sus trayectorias académicas, proporcionándoles recursos y orientación para mejorar su rendimiento y su experiencia universitaria. La satisfacción estudiantil es un indicador clave de la eficacia de estos programas, ya que la percepción positiva de los estudiantes sobre los servicios y el apoyo recibidos está estrechamente relacionada con su compromiso y desempeño académico (Tinto, 2012).

Variables y Medición en el Modelo de Evaluación

Para la evaluación de programas de tutoría, se proponen las siguientes variables:

- **Desempeño Académico:** Medido mediante las calificaciones

obtenidas antes y después de participar en el programa de tutoría.

- **Satisfacción Estudiantil:** Evaluada mediante encuestas que incluyen dimensiones como apoyo percibido, accesibilidad del tutor y relevancia del contenido de la tutoría.

Caso: “Inteligencia emocional, competencias y desempeño del docente universitario: Aplicando la técnica mínimos cuadrados parciales SEM-PLS”

Se presenta un análisis detallado de cómo la inteligencia emocional (IE) influye en las competencias docentes y, a su vez, en el desempeño profesional. Utiliza la técnica PLS-SEM para validar un modelo que explora estas relaciones en el contexto universitario.

Modelo Conceptual

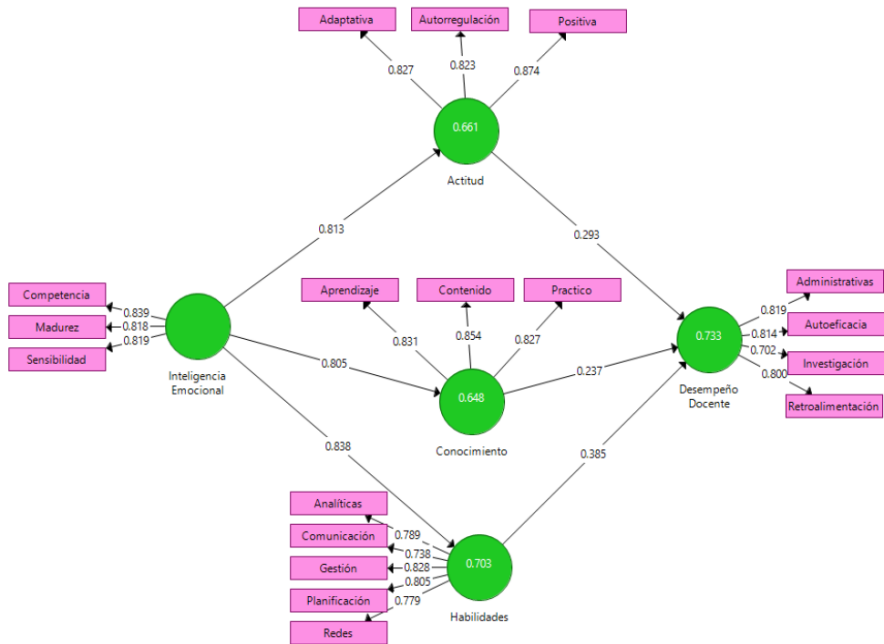
El modelo propuesto incluye las siguientes variables latentes:

1. **Inteligencia Emocional (IE):** Se mide a través de tres dimensiones principales:
 - Madurez: Reconocimiento y control de las emociones propias.
 - Sensibilidad: Mejoramiento de relaciones interpersonales y transmisión emocional positiva.
 - Competencia emocional: Manejo efectivo de trastornos emocionales y respuesta creativa ante impulsos emocionales.
2. **Competencias Docentes:** Incluye conocimiento, habilidades y actitudes necesarias para el proceso educativo.

3. **Desempeño Docente:** Evalúa la calidad de la enseñanza y la autorrealización personal y profesional.

Figura 26

Modelo SEM del estudio



Hipótesis del Estudio

1. **H1:** La IE tiene un impacto positivo en las competencias docentes.
2. **H2:** Las competencias docentes influyen positivamente en el desempeño docente.
3. **H3:** La IE afecta indirectamente el desempeño docente a través de las competencias docentes.

Resultados Clave

- **Índices de ajuste del modelo:**
 - El modelo mostró un buen ajuste con valores significativos en los indicadores de validez y fiabilidad (AVE y Alfa de Cronbach superiores a 0.7).
- **Impacto directo:**
 - IE → Competencias Docentes: $\beta = 0.68$, $p < 0.01$.
 - Competencias Docentes → Desempeño Docente: $\beta = 0.72$, $p < 0.01$.
- **Efecto mediador:**
 - IE influye indirectamente en el desempeño docente a través de las competencias, confirmando la importancia de las habilidades emocionales como base para un desempeño óptimo.

Aplicaciones Prácticas

Este modelo SEM proporciona evidencia empírica sobre la importancia de integrar el desarrollo de la inteligencia emocional en los programas de formación docente. Los resultados sugieren que:

1. Incluir talleres de IE puede mejorar la interacción docente-estudiante y la calidad educativa.
2. Fomentar competencias emocionales promueve un ambiente de aprendizaje más saludable y efectivo.

Artículo disponible en: [Vista de Inteligencia emocional, competencias y desempeño del docente universitario: Aplicando la técnica mínimos cuadrados parciales SEM-PLS](#)

Caso de Estudio: Eficacia de Programas de Tutoría en Universidades Públicas de Bolivia

Este caso de estudio se centra en evaluar la eficacia de programas de tutoría en universidades públicas bolivianas. El objetivo es identificar si los estudiantes que participan en estos programas muestran mejoras significativas en su rendimiento académico y mayor satisfacción con la educación recibida.

Planteamiento del Modelo

Para analizar la eficacia de los programas de tutoría, se plantea un modelo de evaluación de efectos de la tutoría en dos variables clave: desempeño académico y satisfacción estudiantil.

Las **variables observadas** en este modelo son:

1. **Desempeño Académico Pre-Tutoría:** Calificación promedio de los estudiantes antes de ingresar al programa de tutoría.
2. **Desempeño Académico Post-Tutoría:** Calificación promedio de los estudiantes después de participar en el programa de tutoría.
3. **Satisfacción con la Tutoría:** Medida a través de una encuesta de satisfacción que evalúa el apoyo recibido, la relación con el tutor y la utilidad de las sesiones.

Procedimiento para el Análisis en SPSS, AMOS y Jamovi

Para analizar los datos en este caso de estudio, se utilizarán SPSS para la manipulación de datos, AMOS para el análisis de ecuaciones estructurales y Jamovi para la verificación de análisis adicionales.

Procedimiento en SPSS

1. **Crear la Base de Datos:** La base de datos debe incluir las siguientes columnas:
 - ID del estudiante
 - Calificación Pre-Tutoría
 - Calificación Post-Tutoría
 - Puntaje de Satisfacción
2. **Realizar Prueba t de Pares:** Comparar las calificaciones pre y post tutoría para evaluar si hubo una mejora significativa en el rendimiento.
 - En SPSS, ir a **Analyze > Compare Means > Paired-Samples T Test.**
 - Seleccionar las variables de calificación antes y después de la tutoría.
 - Interpretar el valor de p ($p < .05$ indica una mejora significativa).
3. **Calcular Estadísticas Descriptivas:** Generar estadísticos descriptivos para la variable de satisfacción estudiantil.

Procedimiento en AMOS

1. **Definir el Modelo SEM:** En AMOS, configurar un modelo de análisis factorial para medir la relación entre la participación en el programa de tutoría (variable independiente) y las variables latentes de desempeño académico y satisfacción estudiantil.

- En el modelo, incluir una flecha que vaya desde la participación en el programa hasta el desempeño y otra hacia la satisfacción.
2. **Ejecutar el Modelo:** Calcular los índices de ajuste (CFI, TLI, RMSEA).
 - **Interpretación:** Valores de CFI y TLI $> .90$ y RMSEA $< .08$ indican un buen ajuste del modelo (Byrne, 2016).
 3. **Examinar Resultados:** Observar las cargas factoriales y las relaciones significativas entre las variables latentes.

Procedimiento en Jamovi

1. **Ingresar la Base de Datos:** Cargar los datos en Jamovi y realizar un **Análisis de Medias** para verificar las diferencias entre las calificaciones antes y después de la tutoría.
2. **Realizar Análisis de SEM:** En Jamovi, utilizar el módulo SEM para replicar el análisis estructural realizado en AMOS.
3. **Interpretar Resultados:** Comparar los resultados de ajuste y las cargas factoriales con los de AMOS.

Interpretación de los Resultados y Toma de Decisiones

- **Desempeño Académico:** Si la prueba t y el modelo SEM muestran una mejora significativa en las calificaciones, se concluye que el programa de tutoría tiene un impacto positivo en el rendimiento académico de los estudiantes.
- **Satisfacción Estudiantil:** Un puntaje de satisfacción elevado sugiere que los estudiantes valoran positivamente la tutoría, lo que

puede indicar un buen ajuste entre el programa y las necesidades estudiantiles.

Este capítulo ha ilustrado cómo evaluar la eficacia de un programa de tutoría en universidades mediante técnicas de análisis cuantitativo en SPSS, AMOS y Jamovi. El uso de SEM permite una comprensión profunda de las relaciones causales entre el programa de tutoría y el desempeño y satisfacción estudiantil, proporcionando una base sólida para tomar decisiones informadas sobre la continuidad y mejora de estos programas en instituciones educativas.

Sección 6: Casos Latinoamericanos y Estudios Comparativos

CAPITULO XIII

Capítulo 13: Casos Internacionales de SEM en Empresas Latinoamericanas

Este capítulo aborda la aplicación de Modelos de Ecuaciones Estructurales (SEM) en empresas de tres países latinoamericanos: Perú, México y Brasil. Se presenta una comparación de modelos SEM en diversos contextos empresariales de estos países, seguida de un caso específico de satisfacción laboral en empresas del sector turístico de Perú y México. Este enfoque permite comprender las similitudes y diferencias en la estructura organizacional y las dinámicas laborales en la región, así como las implicancias culturales y socioeconómicas que afectan estos modelos.

Comparación de Modelos SEM en Empresas de Perú, México y Brasil

La comparación de modelos SEM en estos tres países revela la diversidad en las estructuras empresariales y el impacto de los factores contextuales en el diseño de los modelos. Un estudio realizado por Silva et al. (2022) en empresas peruanas de manufactura analizó cómo el compromiso organizacional y el liderazgo afectan el desempeño de los empleados. Utilizando SEM, los autores encontraron que el liderazgo transformacional tiene un

efecto positivo y directo sobre el compromiso de los empleados, lo cual se traduce en una mayor productividad. Este modelo se estructura en base a variables endógenas como el desempeño laboral y variables exógenas como el liderazgo y el ambiente de trabajo.

En contraste, en México, se observa un énfasis en las relaciones entre satisfacción laboral, motivación y rotación de personal en el sector minorista. Un estudio de Gómez y Martínez (2021) encontró que la motivación laboral es un factor mediador entre la satisfacción laboral y la intención de rotación en empleados de tiendas departamentales. Este modelo SEM fue diseñado con una estructura jerárquica donde la satisfacción laboral se coloca como variable exógena, y la intención de rotación como variable endógena, con la motivación laboral desempeñando un rol de mediación.

Brasil, por otro lado, presenta una estructura más compleja en el análisis de modelos SEM debido a su tamaño y diversidad económica. En un estudio de Almeida y Santos (2023) en empresas tecnológicas de São Paulo, se evaluó el impacto de la cultura organizacional y la innovación en la satisfacción laboral y la retención de talento. La investigación utilizó un modelo SEM no jerárquico, dado que algunas de las variables endógenas como la retención de talento actúan también como variables causales en el modelo. Este tipo de diseño refleja la dinámica laboral en el sector

tecnológico de Brasil, donde la innovación es tanto un efecto como una causa de la satisfacción laboral.

La comparación de estos modelos en Perú, México y Brasil evidencia las particularidades de cada contexto y la necesidad de adaptar los modelos SEM a las características específicas de cada entorno empresarial. En cada caso, se observa cómo los factores organizacionales y culturales determinan la estructura del modelo y las relaciones entre las variables.

Caso Comparativo: Satisfacción Laboral en Empresas del Sector Turístico de Perú y México

El sector turístico en América Latina enfrenta desafíos únicos, incluyendo la estacionalidad de la demanda, la alta rotación de personal y la necesidad de mantener elevados niveles de satisfacción laboral para asegurar la calidad del servicio. Este caso comparativo se centra en el análisis de la satisfacción laboral en empresas del sector turístico de Perú y México, utilizando SEM para examinar las variables que influyen en la satisfacción y su relación con el desempeño y la retención de empleados.

En Perú, un estudio reciente de Castillo y Alvarado (2023) en empresas turísticas de Cusco encontró que la satisfacción laboral está significativamente influenciada por la percepción de estabilidad laboral y las oportunidades de crecimiento profesional.

Usando un modelo SEM, los investigadores establecieron que estas

dos variables tienen un efecto directo sobre la satisfacción laboral, mientras que la estabilidad laboral también actúa como un mediador entre el ambiente de trabajo y la satisfacción laboral. La estructura jerárquica del modelo refleja una dependencia secuencial en la que los factores de estabilidad y crecimiento conducen a una mayor satisfacción, lo cual a su vez disminuye la intención de rotación.

En México, en empresas del sector turístico de Cancún, Hernández y Reyes (2022) desarrollaron un modelo SEM para analizar cómo la compensación y el ambiente de trabajo afectan la satisfacción y el compromiso organizacional. La investigación encontró que la compensación es una variable exógena que influye positivamente en la satisfacción laboral, y esta, a su vez, tiene un efecto directo en el compromiso organizacional. Este modelo también incluye un componente de mediación, donde el ambiente de trabajo modera la relación entre compensación y compromiso.

Al comparar ambos casos, se observa que la estabilidad laboral es un factor clave en Perú, mientras que, en México, la compensación desempeña un rol predominante. Esto sugiere que las prioridades y las expectativas de los empleados pueden variar significativamente según el contexto económico y cultural de cada país. Los modelos SEM permiten capturar estas diferencias y analizar cómo los distintos factores organizacionales contribuyen a la satisfacción y retención de los empleados en el sector turístico.

La aplicación de SEM en estos estudios comparativos demuestra su utilidad para identificar patrones y relaciones complejas entre variables organizacionales en diferentes contextos culturales y empresariales. Los hallazgos resaltan la importancia de adaptar los modelos SEM a las particularidades de cada país, lo que resulta esencial para generar estrategias organizacionales efectivas y mejorar la retención y satisfacción laboral en el sector empresarial latinoamericano.

CAPITULO XIV

Capítulo 14: Aplicaciones en Contextos Interculturales

Este capítulo explora el uso de Modelos de Ecuaciones Estructurales (SEM) en contextos multiculturales, haciendo énfasis en los desafíos de adaptación y validación de estos modelos cuando se aplican a diferentes grupos culturales. También se presenta un estudio de caso sobre la percepción de igualdad de género en los ambientes laborales en Colombia y Perú, lo que permite observar cómo los factores culturales y sociales influyen en la percepción de equidad en estos dos países latinoamericanos.

Desafíos de la Adaptación y Validación de SEM en Contextos Multiculturales

La aplicación de SEM en contextos multiculturales plantea importantes retos metodológicos. Uno de los desafíos principales es asegurar la **equivalencia semántica y conceptual** de los constructos, es decir, que los conceptos empleados en el modelo mantengan el mismo significado en diferentes culturas. Según Byrne (2021), una de las formas de abordar esta cuestión es mediante la traducción y adaptación cultural de los ítems, lo que implica realizar pruebas de consistencia interna y validez factorial para garantizar que los instrumentos de medición son igualmente relevantes y comprensibles para los diferentes grupos.

Otro desafío significativo es la **equivalencia de medición**, que se refiere a si las escalas y estructuras factoriales son consistentes a través de los grupos culturales. Chen et al. (2022) explican que esto se evalúa mediante análisis de invarianza factorial, un procedimiento estadístico que permite comparar modelos SEM en diferentes culturas. Sin embargo, lograr invarianza completa es difícil en contextos interculturales, por lo que los investigadores deben a menudo conformarse con grados menores de invarianza (como invarianza configuracional o métrica), lo cual puede limitar las conclusiones sobre la comparabilidad de los constructos entre los grupos.

Finalmente, existe el reto de la **interpretación cultural de los resultados**. Los valores y normas culturales influyen en la percepción de las variables latentes como el liderazgo, la satisfacción laboral y la igualdad de género. Así, incluso si se logra la equivalencia de medición, los factores contextuales deben considerarse al interpretar los resultados. Este proceso exige un conocimiento profundo de las diferencias culturales y contextuales, así como la colaboración con investigadores locales para interpretar adecuadamente los datos y evitar sesgos interpretativos.

Caso: Analisis del Modelo SEM del Artículo "Developing Intercultural Efficiency: The Relationship between Cultural Intelligence and Self-Efficacy"

Este estudio utiliza el modelo PLS-SEM para analizar la relación entre la **Inteligencia Cultural (CQ)** y la **Autoeficacia Intercultural (SE)**, evaluando además los efectos moderadores de dos variables categóricas:

1. **Experiencia Laboral en el Extranjero**
2. **Género**

El modelo conceptual incluye:


- **Variable Exógena:** Inteligencia Cultural (CQ).
- **Variable Endógena:** Autoeficacia (SE).
- **Moderadores:** Experiencia laboral en el extranjero y género.

Hipótesis

1. **H1:** La Inteligencia Cultural (CQ) afecta positivamente la Autoeficacia Intercultural (SE).
2. **H2:** La Experiencia Laboral en el Extranjero modera la relación entre CQ y SE, aumentando su impacto.
3. **H3:** El Género no tiene un efecto moderador en la relación entre CQ y SE.

Figura 27

Modelo: Teórico del estudio



Diseño del Estudio

- **Muestra:** 190 estudiantes universitarios.
- **Método:**
 - Cuestionarios para medir CQ y SE.
 - PLS-SEM para estimar relaciones causales y efectos moderadores.

Resultados

1. Impacto Directo:

- CQ → SE: Relación positiva y significativa.

2. Moderación por Experiencia Laboral:

- Refuerza significativamente la relación CQ → SE.

3. Moderación por Género:

- No afecta significativamente la relación CQ → SE.

Aplicación Práctica

Este modelo SEM es relevante para diseñar programas de desarrollo intercultural en organizaciones globales. Las empresas pueden centrarse en desarrollar CQ, especialmente en empleados con experiencia laboral internacional, para mejorar la eficacia en entornos multiculturales. Artículo disponible en: <https://www.mdpi.com/2076-0760/10/8/312>

Caso de Estudio: Percepción de Igualdad de Género en Ambientes Laborales en Colombia y Perú

Este estudio de caso examina la percepción de igualdad de género en los ambientes laborales de Colombia y Perú, utilizando SEM para modelar las relaciones entre variables como el apoyo organizacional, la cultura corporativa y la percepción de equidad de género. La investigación permite observar cómo los contextos socioculturales influyen en la percepción de igualdad y en los factores que contribuyen a la misma en ambos países.

Contexto y Metodología

La igualdad de género en el lugar de trabajo es un tema cada vez más relevante en América Latina. En este contexto, se aplicó un modelo SEM en una muestra de empleados de empresas medianas y grandes en Colombia y Perú para evaluar cómo la cultura organizacional y las políticas de igualdad influyen en la percepción

de equidad de género. La muestra incluyó a 500 empleados en cada país, quienes respondieron a un cuestionario estandarizado que medía percepciones sobre el apoyo organizacional, la presencia de políticas de igualdad y el nivel de equidad percibido entre géneros.

El modelo SEM fue diseñado con la **percepción de igualdad de género** como variable dependiente, mientras que el **apoyo organizacional** y la **cultura corporativa** fueron consideradas como variables independientes. Además, se incluyó una variable mediadora, **políticas de igualdad**, para analizar su efecto en la relación entre las variables independientes y la percepción de igualdad.

Resultados en Colombia

En el caso de Colombia, el análisis SEM reveló que la percepción de igualdad de género está fuertemente influenciada por la cultura organizacional, específicamente en empresas donde se fomenta un ambiente inclusivo y respetuoso. Además, el apoyo organizacional fue significativo, aunque menos fuerte en comparación con el impacto de la cultura corporativa. Las políticas de igualdad mediaron parcialmente la relación entre cultura organizacional y percepción de equidad, sugiriendo que, aunque la cultura organizacional es fundamental, la implementación de políticas explícitas refuerza la percepción de igualdad de género (Martínez et al., 2023).

Estos resultados reflejan un contexto en el que las normas culturales en Colombia aún mantienen ciertas desigualdades de género, pero el esfuerzo organizacional por fomentar una cultura inclusiva puede compensar estos sesgos, especialmente cuando se implementan políticas de igualdad que institucionalizan el respeto y la equidad de género.

Resultados en Perú

En Perú, el modelo SEM mostró una dependencia más significativa del apoyo organizacional directo sobre la percepción de igualdad de género, mientras que la cultura corporativa tuvo un efecto indirecto mediado por las políticas de igualdad. Esto sugiere que, en el contexto peruano, la percepción de equidad depende más de los mecanismos formales de apoyo organizacional, tales como el acceso a recursos y beneficios, que de la cultura organizacional en sí misma. La mediación de las políticas de igualdad fue más fuerte en Perú que en Colombia, lo cual podría indicar una menor internalización cultural de la igualdad de género en las prácticas organizacionales peruanas (Vásquez & Rojas, 2024).

Este hallazgo pone de relieve que, en el contexto peruano, las políticas explícitas de igualdad tienen un papel crucial en la percepción de equidad, ya que los empleados parecen confiar en la formalización de políticas de igualdad para percibir un ambiente de trabajo justo, más allá de los valores organizacionales.

Discusión Comparativa

La comparación de los resultados en Colombia y Perú subraya las diferencias culturales en la percepción de igualdad de género. Mientras que en Colombia la cultura organizacional juega un papel más influyente en la percepción de equidad, en Perú el apoyo organizacional y la presencia de políticas específicas de igualdad son más determinantes. Estos hallazgos sugieren que en países donde la equidad de género aún no es un valor completamente internalizado, las políticas explícitas de igualdad son esenciales para generar percepciones de justicia y equidad en el lugar de trabajo.

El análisis también destaca la importancia de adaptar y validar los modelos SEM en estudios multiculturales. En este caso, la falta de invarianza completa entre los modelos de Colombia y Perú limita las conclusiones sobre la comparabilidad directa de los factores, aunque proporciona valiosa información contextual sobre cómo diferentes culturas perciben la igualdad de género en el trabajo.

Este capítulo demuestra la complejidad de aplicar SEM en contextos interculturales y enfatiza la importancia de adaptar los modelos a las especificidades de cada cultura. A través del caso de estudio sobre la igualdad de género en Colombia y Perú, se evidencia cómo factores culturales y organizacionales pueden

afectar la percepción de equidad, y cómo SEM puede ayudar a desentrañar estas relaciones en contextos complejos y diversos.

CAPITULO XV

Capítulo 15: SEM y Ciencia de Datos

En este capítulo, exploramos la integración de Modelos de Ecuaciones Estructurales (SEM) con técnicas de Ciencia de Datos, como Machine Learning (ML) y Big Data, para abordar problemas complejos en el análisis de datos masivos y no estructurados. Esta combinación permite aprovechar las fortalezas de SEM en el análisis de relaciones causales y de ML en la predicción y manejo de grandes volúmenes de datos, lo que es especialmente relevante en contextos empresariales como el comercio electrónico. A través de un estudio de caso sobre la predicción de patrones de compra en plataformas de comercio electrónico en Brasil y Argentina, ilustramos cómo estas herramientas pueden aplicarse para obtener una visión más completa de los factores que influyen en el comportamiento de los consumidores.

Integración de SEM con Machine Learning y Big Data

La integración de SEM con Machine Learning y Big Data ha cobrado importancia en los últimos años, ya que cada técnica complementa las limitaciones de la otra. SEM es útil para analizar relaciones causales complejas entre variables latentes y observables, permitiendo validar modelos teóricos que explican fenómenos

sociales o de mercado. Sin embargo, SEM está tradicionalmente limitado por el tamaño de las muestras y la capacidad de manejar datos no estructurados, lo que limita su aplicabilidad en contextos de Big Data (Zhou et al., 2023).

Por otro lado, los métodos de Machine Learning y Big Data son capaces de procesar grandes volúmenes de datos y realizar análisis predictivos, pero carecen de la capacidad interpretativa y la estructura teórica que SEM proporciona. La combinación de estas herramientas permite construir modelos robustos que no solo explican, sino que también predicen comportamientos, y se ajustan a las necesidades de análisis en tiempo real en sectores como el comercio electrónico (Kim & Seo, 2022).

Una de las formas de integración es el uso de técnicas de Machine Learning para preprocesar grandes cantidades de datos no estructurados, como los obtenidos de redes sociales, clics en sitios web o búsquedas en plataformas de comercio electrónico. Estos datos se estructuran y sintetizan mediante algoritmos de ML, y luego se integran en modelos SEM para analizar las relaciones entre variables. Otra metodología implica el uso de SEM para definir las relaciones causales y usar Machine Learning para optimizar las predicciones basadas en el modelo estructural.

Caso de Estudio: Predicción de Patrones de Compra en Plataformas de Comercio Electrónico en Brasil y Argentina

Este caso de estudio se centra en la predicción de patrones de compra en plataformas de comercio electrónico en Brasil y Argentina, utilizando una integración de SEM y técnicas de Machine Learning. El objetivo es identificar los factores que influyen en las decisiones de compra y predecir comportamientos futuros en estos dos mercados, permitiendo a las empresas ajustar sus estrategias de marketing y personalización en tiempo real.

Contexto y Metodología

Brasil y Argentina son dos de los mercados de comercio electrónico más grandes de América Latina, con millones de usuarios activos y un crecimiento exponencial en los últimos años. Para este estudio, se recogieron datos de transacciones en línea de ambas naciones durante un año, incluyendo variables como la frecuencia de compra, el tipo de productos, el monto gastado, el método de pago y la respuesta a promociones. Los datos no estructurados, como los comentarios de los usuarios y el comportamiento de clics, también se incluyeron en el análisis.

La metodología consistió en tres etapas principales:

1. **Preprocesamiento de Datos:** Se utilizó procesamiento de lenguaje natural (NLP) y técnicas de análisis de sentimientos para estructurar los comentarios y reseñas de productos. El comportamiento de clics y las interacciones en la plataforma se codificaron en variables observables mediante técnicas de clustering.

2. **Desarrollo del Modelo SEM:** Basado en la teoría de comportamiento del consumidor, se construyó un modelo SEM que incluye variables latentes como **satisfacción del cliente**, **lealtad** y **percepción de valor**. Estas variables latentes se relacionan con variables observables derivadas de los datos, como frecuencia de compra, gasto promedio y respuesta a promociones.
3. **Aplicación de Machine Learning:** Finalmente, se emplearon algoritmos de ML como redes neuronales y árboles de decisión para optimizar la predicción de las variables latentes en el modelo SEM, permitiendo hacer predicciones en tiempo real y ajustar el modelo según se acumulen nuevos datos.

Resultados en Brasil

En el mercado brasileño, los resultados indicaron que la **satisfacción del cliente** y la **percepción de valor** tienen una relación directa y significativa con la frecuencia de compra y el gasto promedio en la plataforma. Los análisis de Machine Learning revelaron que las promociones personalizadas aumentan la probabilidad de compra en un 25% en usuarios satisfechos, mientras que los consumidores con una baja percepción de valor rara vez responden a promociones, independientemente de su frecuencia.

El uso de SEM permitió confirmar que la **lealtad** mediaba la relación entre la satisfacción y la frecuencia de compra. Los algoritmos de ML ayudaron a predecir la probabilidad de lealtad de

los clientes en función de su comportamiento pasado y sus interacciones en la plataforma. Esto permitió implementar estrategias de retención para clientes de alta lealtad y estrategias de adquisición para los nuevos usuarios.

Resultados en Argentina

En Argentina, los resultados mostraron que la **percepción de valor** era el predictor más fuerte del gasto promedio en la plataforma, mientras que la **satisfacción del cliente** tenía un menor impacto directo. Sin embargo, la aplicación de SEM reveló que la percepción de valor estaba indirectamente influenciada por las opiniones de otros consumidores, un factor capturado a través del análisis de sentimientos en comentarios y reseñas.

A través de algoritmos de Machine Learning, se identificaron patrones en los que los consumidores argentinos eran más propensos a realizar compras impulsivas cuando veían reseñas positivas de otros usuarios. El modelo SEM ayudó a estructurar esta relación causal, y los algoritmos de ML permitieron predecir qué tipo de comentarios tendrían mayor impacto en diferentes perfiles de clientes.

Discusión Comparativa

La comparación de los resultados en Brasil y Argentina muestra que, aunque existen similitudes en los factores que influyen en los patrones de compra, también hay diferencias significativas en

la forma en que los consumidores perciben el valor y responden a las promociones. En Brasil, las promociones personalizadas tienen un fuerte efecto en la frecuencia de compra, lo que sugiere que los consumidores brasileños responden bien a la personalización y el marketing dirigido. En contraste, los consumidores argentinos parecen estar más influenciados por el contenido generado por otros usuarios, como comentarios y reseñas, lo que indica un alto valor social asociado a la percepción de productos y servicios.

Ejemplos Prácticos de Aplicación

1. **Recomendaciones de Productos Personalizadas:** Utilizando el modelo SEM y las predicciones de ML, las plataformas de comercio electrónico pueden personalizar las recomendaciones de productos según la satisfacción y lealtad del cliente. Por ejemplo, si un cliente muestra una alta satisfacción y ha respondido bien a promociones pasadas, el sistema puede priorizar recomendaciones de productos similares o ofrecer promociones exclusivas.
2. **Segmentación Dinámica de Clientes:** Con base en los resultados del análisis SEM y ML, es posible segmentar a los clientes de forma dinámica en función de sus comportamientos y percepciones. Esto permite a las empresas ajustar sus estrategias de marketing de manera personalizada. Por ejemplo, en Argentina, el enfoque puede estar en destacar reseñas y opiniones de usuarios para atraer a

nuevos clientes, mientras que, en Brasil, una estrategia de descuentos personalizados puede ser más efectiva.

3. **Optimización de Campañas de Marketing:** Los algoritmos de ML optimizados por SEM permiten prever la respuesta de los clientes a diferentes tipos de campañas, como descuentos y ofertas de tiempo limitado. En Brasil, las plataformas pueden implementar campañas de marketing más efectivas dirigidas a clientes leales, mientras que en Argentina se puede fomentar la creación de contenido positivo en redes sociales y comentarios de productos para atraer nuevos compradores.

La integración de SEM con Machine Learning y Big Data ofrece una poderosa combinación para analizar y predecir comportamientos de compra en el comercio electrónico. Los hallazgos del estudio de caso en Brasil y Argentina demuestran que esta metodología permite a las empresas comprender mejor las preferencias de los consumidores y adaptar sus estrategias de marketing en tiempo real, maximizando así su efectividad.

Caso Práctico de SEM: Análisis de cómo el marketing en redes sociales (SNM) afecta el comportamiento de compra de los consumidores (CPB) en Facebook Marketplace

El artículo "*Social Networks Marketing and Consumer Purchase Behavior: The Combination of SEM and Unsupervised Machine Learning Approaches*" analiza cómo el marketing en redes sociales (SNM) afecta el comportamiento de compra de los consumidores (CPB) en Facebook

Marketplace. Basado en este estudio, se puede desarrollar un caso práctico detallado siguiendo los pasos principales del análisis SEM:


Planteamiento del Modelo Conceptual

Dimensiones de SNM evaluadas:

1. **Entretenimiento (ENT):** Atractivo del contenido para los usuarios.
2. **Personalización (CUS):** Ajuste de servicios a las preferencias individuales.
3. **Interacción (INT):** Comunicación bidireccional entre usuarios.
4. **Boca a boca (WoM):** Recomendaciones de usuarios.
5. **Tendencias (TRE):** Actualización en información y novedades.

Figura 28

Modelo Teórico del estudio



Variable dependiente: Comportamiento de compra del consumidor (CPB).

Hipótesis del estudio:

- **H1:** El entretenimiento influye positivamente en el CPB.
- **H2:** La personalización influye positivamente en el CPB.
- **H3:** La interacción influye positivamente en el CPB.
- **H4:** El boca a boca influye positivamente en el CPB.
- **H5:** Las tendencias influyen positivamente en el CPB.

Pasos de Análisis SEM

1. Recolección de datos

- Encuesta distribuida a 466 usuarios de Facebook Marketplace en Hungría.
- Escala Likert de 5 puntos para evaluar las dimensiones y el CPB.

2. Evaluación del modelo de medición

- Verificación de la confiabilidad mediante Alfa de Cronbach (>0.7).
- Validación discriminante usando el ratio HTMT (<0.9).

3. Modelo estructural

- Evaluación del ajuste del modelo:
 - **R²:** 84.1% del CPB explicado por las dimensiones de SNM.
 - **SRMR:** 0.058, indicando un buen ajuste.

Resultados de las hipótesis:

- **H1** (ENT → CPB): $\beta = 0.369$, $p < 0.01$ → Apoyada.
- **H2** (CUS → CPB): $\beta = 0.136$, $p < 0.01$ → Apoyada.

- **H3** (INT → CPB): $\beta = 0.353$, $p < 0.01$ → Apoyada.
- **H4** (WoM → CPB): $\beta = 0.069$, $p < 0.05$ → Apoyada.
- **H5** (TRE → CPB): $\beta = 0.095$, $p < 0.05$ → Apoyada.

Ejemplo de aplicación práctica:

Supongamos que una empresa quiere mejorar su estrategia de marketing en Facebook Marketplace. A través del SEM, identificaron que "**Interacción**" y "**Entretenimiento**" son los factores más influyentes en el comportamiento de compra. Como respuesta, decidieron:

1. Implementar juegos interactivos para aumentar el tiempo en la plataforma.
2. Personalizar las recomendaciones basadas en las búsquedas previas de los usuarios.

Modelo SEM

Incluye las relaciones entre las dimensiones (ENT, CUS, INT, WoM, TRE) y la variable dependiente CPB, mostrando los coeficientes de impacto y la validez del modelo.

Estudio disponible en: [https://doi.org/10.3390/bdcc6020035\(BDCC-06-00035-v2\)](https://doi.org/10.3390/bdcc6020035(BDCC-06-00035-v2)).

CAPITULO XVI

Capítulo 16: Aplicaciones Prácticas para realizar SEM

Los Modelos de Ecuaciones Estructurales (SEM) ofrecen un marco estadístico poderoso para modelar relaciones causales complejas, convirtiéndolos en herramientas esenciales en diversas áreas de investigación aplicada. Este capítulo aborda aplicaciones prácticas de SEM en campos como la educación, el marketing, los recursos humanos y las ciencias sociales, con ejemplos específicos para ilustrar su utilidad.

PROCEDIMIENTO PASO A PASO PARA REALIZAR LA PRUEBA DE FIABILIDAD

La prueba de fiabilidad evalúa la consistencia interna de un instrumento de medición, como un cuestionario o escala, para asegurar que los ítems relacionados midan el mismo constructo. Una de las métricas más comunes es el **Alfa de Cronbach**.

Hipótesis sobre la consistencia interna del instrumento

- **H1:** El instrumento tiene una consistencia interna alta, indicando que todos los ítems miden un constructo común.
- **H2:** La eliminación de ítems redundantes o poco informativos no afectaría significativamente el valor del Alfa de Cronbach, debido a su robustez actual.

1. Preparación de los Datos

1. Recopilación de datos:

- Asegúrate de que las respuestas de los ítems sean recopiladas en una escala numérica uniforme (por ejemplo, Likert de 1 a 5).
- Cada ítem debe medir aspectos del mismo constructo.

2. Verificación de los datos:

- Revisa valores perdidos.
- Imputa datos si es necesario, pero evita imputaciones excesivas para mantener la validez del análisis.

2. Cálculo del Alfa de Cronbach en un Software Estadístico

En SPSS

1. Abrir el conjunto de datos:

- Carga los datos en formato SPSS (.sav).

2. Ir a la opción de análisis:

- Haz clic en Analyze > Scale > Reliability Analysis.

3. Seleccionar los ítems:

- En la ventana emergente, mueve las variables correspondientes a la escala al recuadro "Items".

4. Elegir el modelo de fiabilidad:

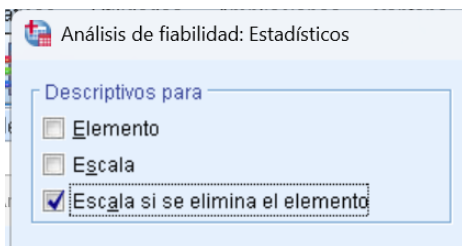
- Asegúrate de que el método seleccionado sea "Alfa".

5. Opciones adicionales:

- Selecciona "Statistics" y activa las opciones "Scale if item deleted" para identificar qué ítems afectan negativamente la fiabilidad.

Figura 29

Fiabilidad: Escala si se elimina el elemento



Para realizar algunos ajustes.

6. Ejecutar el análisis:

- Haz clic en "OK" para obtener los resultados.

En Jamovi

1. Carga el archivo de datos.

2. Ve al módulo Reliability Analysis (puede requerir instalación previa).
3. Selecciona las variables de interés.
4. Configura las métricas deseadas, como "Alfa de Cronbach" y "Ítem total".
5. Revisa los resultados en tiempo real.

En R (paquete psych)

R

Copiar código

```
library(psych)
```

```
# Suponiendo que tus datos están en un data frame llamado "datos"  
con columnas para cada ítem
```

```
alpha(datos)
```

3. Interpretación de los Resultados

1. Alfa de Cronbach:

- Valores ≥ 0.7 generalmente son aceptables.
- Valores ≥ 0.8 son buenos, y ≥ 0.9 excelentes.

2. Criterios adicionales:

- **Ítem-total corregido:** Identifica ítems con correlaciones bajas (< 0.3) con el puntaje total, ya que pueden ser redundantes o no estar relacionados con el constructo.
- **"Alpha if item deleted":** Evalúa si la eliminación de un ítem mejora la fiabilidad general.

4. Validación Adicional

1. Pruebas complementarias:

- Calcula índices adicionales como la Fiabilidad Compuesta (CR) o el AVE en análisis SEM.

2. Evaluación conceptual:

- Asegúrate de que los ítems con baja correlación sean evaluados desde una perspectiva teórica antes de eliminarlos.

Un cuestionario de 5 ítems sobre satisfacción laboral es aplicado a 200 empleados. El análisis en SPSS muestra un Alfa de Cronbach de 0.82, lo que indica buena consistencia interna. Al revisar "Alpha if item deleted", se observa que un ítem aumenta el Alfa a 0.85 si se elimina. Esto sugiere que este ítem no es consistente con el resto de la escala.

El análisis de fiabilidad es crucial para garantizar que las escalas sean consistentes y reflejen con precisión el constructo de interés. Al seguir este procedimiento, puedes identificar áreas de mejora en tus instrumentos de medición y reforzar la validez de los resultados.

Nota:

- **Confiabilidad de un instrumento de medición:** Se refiere a la capacidad del instrumento para proporcionar resultados consistentes cuando se aplica en más de una ocasión bajo las mismas condiciones.
- **Importancia en encuestas:** Garantiza la calidad de los datos recopilados al confirmar que las preguntas fueron claras y comprendidas correctamente por los encuestados. Asimismo, asegura que las respuestas reflejan auténticamente las creencias o actitudes de los participantes, reduciendo el riesgo de sesgos o interpretaciones erróneas.

PROCEDIMIENTO PARA LA TOMA DE DECISIONES SOBRE LA PRUEBA DE CORRELACIÓN

Paso 1: Análisis de las pruebas de normalidad

Pruebas de normalidad

	Kolmogorov-Smirnov ^a		Shapiro-Wilk			
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Inbound Marketing	,118	384	,000	,887	384	,000
Posicionamiento de marca	,173	384	,000	,844	384	,000

a. Corrección de significación de Lilliefors

Se han realizado dos pruebas de normalidad para los dos conjuntos de datos: **Inbound Marketing** y **Posicionamiento de marca**. Estas pruebas son **Kolmogorov-Smirnov** y **Shapiro-Wilk**, que nos indican si los datos siguen una distribución normal.

Resultados de las pruebas:

- **Inbound Marketing:**
 - **Kolmogorov-Smirnov:** Estadístico = 0.118, p-value = 0.000
 - **Shapiro-Wilk:** Estadístico = 0.887, p-value = 0.000
- **Posicionamiento de marca:**
 - **Kolmogorov-Smirnov:** Estadístico = 0.173, p-value = 0.000
 - **Shapiro-Wilk:** Estadístico = 0.844, p-value = 0.000

Interpretación de los resultados:

- En ambas pruebas (Kolmogorov-Smirnov y Shapiro-Wilk), el **valor p es menor que 0.05**. Esto indica que **rechazamos la hipótesis nula** de normalidad. Es decir, los datos **no siguen una distribución normal** en ambos casos.

- Por lo tanto, podemos concluir que los datos no tienen una distribución normal y debemos buscar un método de correlación adecuado para datos no normales.

Hipótesis:

- **Hipótesis Nula (H0):** Los datos de la variable siguen una distribución normal.
- **Hipótesis Alterna (H1):** Los datos de la variable no siguen una distribución normal.

Paso 2: Determinación de la prueba de correlación adecuada

Cuando se trata de analizar la relación entre dos variables, la **prueba de correlación** es esencial. Sin embargo, la elección de la prueba de correlación depende de si los datos cumplen con los supuestos de normalidad.

1. Si los datos fueran normales:

Si ambos conjuntos de datos siguieran una distribución normal, la prueba de correlación más común sería la **correlación de Pearson**, que evalúa la fuerza y la dirección de una relación lineal entre dos variables.

2. Si los datos no son normales:

Dado que los resultados de las pruebas de normalidad indican que **los datos no son normales**, no es apropiado utilizar la **correlación de Pearson**. En su lugar, debemos optar por una **prueba de correlación no paramétrica**.

La **mejor prueba de correlación no paramétrica** para este tipo de datos es la **correlación de Spearman**.

Paso 3: Correlación de Spearman

La **correlación de Spearman** es una prueba no paramétrica que

evalúa la relación monótona (pero no necesariamente lineal) entre dos variables. A diferencia de Pearson, Spearman no requiere que los datos sigan una distribución normal. En cambio, se basa en los rangos de los datos y es especialmente útil cuando los datos son ordinales, tienen distribuciones sesgadas, o no cumplen con los supuestos de normalidad.

Características de la correlación de Spearman:

- No asume normalidad en los datos.
- Mide la relación monótona entre las variables, lo que significa que la relación puede ser creciente o decreciente, pero no necesariamente de manera lineal.
- Es adecuada para datos ordinales o cuando los datos continuos no cumplen los supuestos de normalidad.

Paso 4: Procedimiento para realizar la prueba de correlación de Spearman

1. **Organización de los datos:** Ordenar los valores de cada variable en rangos.
2. **Cálculo de los rangos:** Asignar a cada valor un rango de acuerdo con su posición en la lista ordenada.
3. **Cálculo de las diferencias de los rangos:** Para cada par de valores correspondientes en las dos variables, calcular la diferencia entre los rangos.

Paso 5: Conclusión y recomendación

Dado que los resultados de las pruebas de normalidad muestran que los datos no siguen una distribución normal, la mejor opción es utilizar la **correlación de Spearman** para analizar la relación entre **Inbound Marketing** y **Posicionamiento de marca**. Esta prueba no paramétrica es adecuada para variables que no cumplen los supuestos de normalidad y proporciona una evaluación robusta de la relación entre las dos variables.

Por lo tanto, se debe proceder con el cálculo del **coeficiente de correlación de Spearman** para determinar la fuerza y dirección de la relación entre estas dos variables en el estudio.

Procedimiento en SPSS:

1. **Abrir SPSS** y cargar los datos.
2. **Analizar > Estadísticos descriptivos > Explorar.**
3. Mover las variables a la lista de **Dependientes.**
4. En **Estadísticos**, seleccionar **Pruebas de normalidad.**
5. Hacer clic en **Aceptar** y revisar los resultados en la salida.
6. **Interpretar los valores p** de Kolmogorov-Smirnov y Shapiro-Wilk para decidir si los datos son normales.

Nota:

- Asegúrate de tener un tamaño de muestra adecuado. Las pruebas de normalidad pueden ser sensibles en muestras pequeñas (menor de 30), por lo que, con muestras grandes, incluso pequeñas desviaciones de la normalidad pueden dar lugar a valores p significativos.
- Además de las pruebas estadísticas, utiliza los **gráficos de normalidad** (como el Q-Q plot o el histograma) para tener una visión visual de la distribución de tus datos.

CRITERIOS DE VALIDACIÓN Y PROCEDIMIENTO EN SPSS AMOS (fiabilidad compuesta “ ρ_c ” ($\rho_c \geq 0.7$) para investigaciones

Paso 1: Preparación de Datos

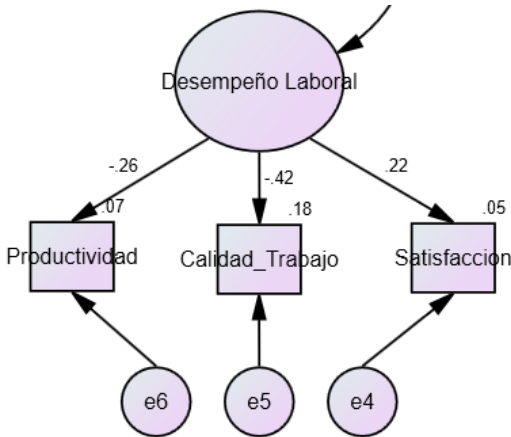

1. Asegúrate de tener el archivo de datos en formato .sav (SPSS).
2. Abre el software AMOS.
3. Carga los datos en AMOS:
 - Haz clic en File > Data Files.
 - Navega hasta tu archivo .sav y selecciónalo.

Paso 2: Construcción del Modelo de Medición

1. **Crear variables latentes:**
 - En el editor gráfico, crea un círculo que represente el constructo latente (por ejemplo, "Fiabilidad").
2. **Agregar variables observadas:**
 - Dibuja rectángulos para cada ítem (por ejemplo, *Item1*, *Item2*, ..., *ItemN*).
3. **Conectar variables:**
 - Traza flechas unidireccionales desde el círculo (constructo) hacia los rectángulos (ítems).

Paso 3: Configuración y Estimación del Modelo

1. Configura el análisis:
 - Asegúrate de que las flechas estén conectadas correctamente.
 - Añade una flecha bidireccional en el constructo latente para representar la varianza.
2. Estima el modelo:
 - Haz clic en Calculate Estimates en la barra de herramientas.
3. Interpreta los resultados:
 - Verifica las cargas factoriales (λ), que deberían ser superiores a 0.7.
 - Calcula manualmente ρ_c y ρ_a si es necesario.



Amos Output

- Scalars
 - Regression Weights:
 - Standardized Regression Weights
 - Covariances:
 - Correlations:
 - Variances:
 - Squared Multiple Correlations:
- Matrices
 - Implied (for all variables) Covariances
 - Implied (for all variables) Correlations
 - Implied Covariances
 - Implied Correlations

		Estimate
Compromiso	<--- CO	.304
Innovacion	<--- CO	-.354
Comunicacion	<--- CO	.034
Satisfaccion	<--- DL	.221
Calidad_Trabajo	<--- DL	-.420
Productividad	<--- DL	-.260

En este caso las cargas factoriales (λ), son < 0.7 no se puede seguir con el modelo se debe hacer ajustes.

GUÍA PARA CALCULAR LA PRUEBA DE KMO Y BARTLETT EN SPSS

Objetivo del Procedimiento

La prueba de KMO y Bartlett evalúa si los datos son adecuados para realizar un análisis factorial exploratorio (AFE). El índice KMO mide la adecuación muestral, y la prueba de esfericidad de Bartlett verifica si las correlaciones entre las variables son significativas.

Pasos para Realizar el Análisis en SPSS

1. Preparación de los Datos

1. Asegúrate de que los datos sean válidos:

- Verifica que las variables estén en formato numérico.
- Asegúrate de que los datos no tengan valores faltantes significativos.

2. Cargar el archivo de datos:

- Abre SPSS y carga el archivo que contiene las variables a analizar.

2. Configuración del Análisis

1. Accede al menú de análisis factorial:

- Ve a Analyze > Dimension Reduction > Factor.

2. Selecciona las variables:

- Mueve las variables que deseas analizar al cuadro "Variables".

3. Configura las opciones de extracción:

- Haz clic en el botón Descriptive.
- Activa las opciones:
 - KMO and Bartlett's test of sphericity.
 - Correlation matrix.
- Haz clic en Continue.

4. Ejecuta el análisis:

- Haz clic en OK para realizar el análisis.

SPSS generará una tabla con los resultados de la prueba de KMO y Bartlett.

1. Interpretación del Índice KMO

Prueba de KMO y Bartlett

Medida Kaiser-Meyer-Olkin de adecuación de muestreo		,863
Prueba de esfericidad de Bartlett	Aprox. Chi-cuadrado	1933,440
	gl	253
	Sig.	,000

- **Ubicación de la tabla:** Busca el valor en la tabla titulada "Kaiser-Meyer-Olkin Measure of Sampling Adequacy".
- **Interpretación de KMO:**
 - **KMO \geq 0.5:** Adecuado para el análisis factorial.
 - **KMO $>$ 0.8:** Muy bueno, las variables están altamente correlacionadas.
 - **KMO $<$ 0.5:** Insuficiente, no se recomienda realizar un AFE.

Ejemplo:

- Si el valor obtenido es **0.863**, se interpreta como una **muy buena adecuación muestral** para proceder con el análisis factorial.

2. Interpretación de la Prueba de Bartlett

- **Ubicación de la tabla:** Busca los resultados en la sección "Bartlett's Test of Sphericity".
- **Componentes de la prueba:**
 - **Chi-cuadrado:** Valor de la estadística calculada.
 - **Grados de libertad (df):** Número de relaciones posibles entre las variables.
 - **Sig. (p-value):** Nivel de significancia.
- **Interpretación de Bartlett:**
 - Si $p < 0.05$, existe suficiente evidencia para concluir que las correlaciones entre las variables son

significativas, lo cual valida la adecuación para el AFE.

- Si $p > 0.05$, las correlaciones no son significativas, y no se recomienda realizar el AFE.

Ejemplo:

- Con un $p = 0.000$, se concluye que las correlaciones entre las variables son estadísticamente significativas.

Conclusión e Implicaciones

1. **Si ambos criterios se cumplen ($KMO \geq 0.5$ y $p < 0.05$):**
 - Procede con el análisis factorial exploratorio.
 - Identifica factores latentes para simplificar el conjunto de datos.
2. **Si no se cumplen:**
 - Revisa la matriz de correlación para detectar variables problemáticas.
 - Considera eliminar variables con baja correlación o redundantes.

Ejemplo Práctico

Supongamos que tienes un conjunto de datos sobre satisfacción laboral con 10 ítems. Al realizar la prueba de KMO y Bartlett, obtienes:

- **KMO:** 0.863 → Muy buena adecuación muestral.
- **Bartlett:** $p = 0.000$ → Correlaciones significativas.

Estos resultados validan que es posible realizar un análisis factorial para identificar factores subyacentes como satisfacción con el liderazgo, condiciones laborales, etc.

Nota: Criterios de validación

- Índice Kaiser-Meyer-Olkin $KMO \geq 0.5$
- Esfericidad de Bartlett ≤ 0.05

Interpretación de las Comunalidades en el Análisis Factorial Exploratorio (AFE)

Las comunalidades representan el porcentaje de la varianza de cada variable que es explicada por los factores comunes extraídos. Según el criterio adoptado (Comunalidades ≥ 0.5), las variables con valores inferiores a 0.5 deben revisarse, ya que podrían no estar contribuyendo significativamente al modelo factorial.

Resultado del SPSS

Comunalidades		
	Inicial	Extracción
HP	1,000	,666
SP	1,000	,844
EP	1,000	,769
GC	1,000	,611
CLC	1,000	,601
CPC	1,000	,528
PCP	1,000	,489
PI	1,000	,557
PVP	1,000	,499
GPV	1,000	,547
PFP	1,000	,720
PC	1,000	,584
TT	1,000	,456
NI	1,000	,749
GN	1,000	,806
R	1,000	,772
OP	1,000	,547
MP	1,000	,456
PNC	1,000	,709
PD	1,000	,658
SC	1,000	,453
FC	1,000	,630
PT	1,000	,588

Método de extracción: análisis de componentes principales.

Criterio Adoptado para Evaluar las Comunalidades

1. Variables con Comunalidad ≥ 0.5 :

- Se consideran bien representadas por el modelo factorial y pueden retenerse en el análisis.

2. Variables con Comunalidad < 0.5 :

- Tienen una representación baja y pueden ser candidatas para eliminación o ajuste si no tienen soporte teórico fuerte.

Análisis de las Comunalidades

Variable	Inicial	Extracción	Evaluación
HP	1.000	0.666	Bien representada (≥ 0.5)
SP	1.000	0.844	Bien representada (≥ 0.5)
EP	1.000	0.769	Bien representada (≥ 0.5)
GC	1.000	0.611	Bien representada (≥ 0.5)
CLC	1.000	0.601	Bien representada (≥ 0.5)
CPC	1.000	0.528	Bien representada (≥ 0.5)
PCP	1.000	0.489	Baja representación (< 0.5)
PI	1.000	0.557	Bien representada (≥ 0.5)
PVP	1.000	0.499	Baja representación (< 0.5)
GPV	1.000	0.547	Bien representada (≥ 0.5)
PFP	1.000	0.720	Bien representada (≥ 0.5)
PC	1.000	0.584	Bien representada (≥ 0.5)
TT	1.000	0.456	Baja representación (< 0.5)
NI	1.000	0.749	Bien representada (≥ 0.5)
GN	1.000	0.806	Bien representada (≥ 0.5)
R	1.000	0.772	Bien representada (≥ 0.5)
OP	1.000	0.547	Bien representada (≥ 0.5)
MP	1.000	0.456	Baja representación (< 0.5)
PNC	1.000	0.709	Bien representada (≥ 0.5)
PD	1.000	0.658	Bien representada (≥ 0.5)
SC	1.000	0.453	Baja representación (< 0.5)
FC	1.000	0.630	Bien representada (≥ 0.5)
PT	1.000	0.588	Bien representada (≥ 0.5)

Conclusión de la Evaluación

1. Variables Bien Representadas (≥ 0.5):

- Un total de 19 variables tienen comunalidades satisfactorias (≥ 0.5) y son adecuadas para ser retenidas en el modelo factorial.

2. Variables con Baja Representación (< 0.5):

- **PCP (0.489), PVP (0.499), TT (0.456), MP (0.456) y SC (0.453).**
- Estas variables tienen una representación limitada en el modelo y deberían revisarse:
 - **Opción 1:** Eliminarlas si no tienen respaldo teórico fuerte.
 - **Opción 2:** Agruparlas con otras variables más significativas si hay relación conceptual.

3. Implicaciones:

- Mantener las variables con comunalidades altas garantiza que los factores extraídos explican una proporción significativa de la varianza total de los datos.
- Revisar las variables con comunalidades bajas ayuda a optimizar el modelo y mejorar su validez.

Siguientes Pasos

1. Rotación de Factores:

- Realiza una rotación (por ejemplo, Varimax) para facilitar la interpretación de los factores y confirmar la contribución de las variables retenidas.

2. Evaluación de la Estructura Factorial:

- Examina las cargas factoriales para identificar qué variables contribuyen más significativamente a cada factor.

3. Validación Teórica:

- Verifica si las variables retenidas tienen sentido teórico y práctico dentro del contexto de la investigación.

Esta interpretación asegura que el modelo factorial sea estadística y conceptualmente sólido.

GUÍA PARA INTERPRETAR LA MATRIZ DE COMPONENTES ROTADOS (rotación varimax)

La matriz de componentes rotados permite identificar qué variables observadas están asociadas más estrechamente con cada componente (factor) tras la rotación Varimax. Este método distribuye las cargas factoriales entre los factores retenidos, facilitando la interpretación y asignación conceptual de las variables a los factores.

Matriz de componente rotado^a

	Componente					
	1	2	3	4	5	6
GN	,829	,117	,123	,256	,086	,129
R	,822	,103	,201	,171	,077	,096
NI	,806	,168	,119	,139	,159	,115
TT	,501	,348	,273	,094	,002	-,019
MP	,048	,618	-,125	,068	,218	-,067
SC	,151	,590	-,111	,188	,184	-,013
OP	,219	,549	,342	,283	-,005	-,001
CPC	,091	,548	,040	,005	,460	,075
PVP	,212	,538	,374	-,108	,106	-,044
GPV	,351	,494	,278	,260	-,079	,170
PCP	,004	,442	,160	,335	,393	-,034
SP	,205	,021	,826	,173	,252	,162
EP	,262	,159	,819	,033	-,049	-,043
HP	,085	-,085	,705	,255	,212	,210
FC	,112	,190	-,011	,717	,135	-,219
PT	,359	-,023	,070	,669	,023	,080
PC	,095	,128	,294	,647	,202	,108
PD	,332	,328	,227	,573	-,141	,201
GC	,044	,098	,108	,060	,760	-,081
CLC	-,040	,393	,075	,011	,652	,118
PI	,347	,112	,116	,168	,615	,062
PNC	,112	-,015	,137	,013	-,169	,805
PFP	,142	-,002	,049	,009	,236	,801

Método de extracción: análisis de componentes principales.

Método de rotación: Varimax con normalización Kaiser.

a. La rotación ha convergido en 9 iteraciones.

Pasos para Interpretar la Matriz

1. Identificar las cargas factoriales significativas:

- Una carga factorial representa la correlación entre una variable y un componente.
- Se consideran significativas las cargas absolutas superiores a **0.40 o 0.50** (dependiendo del contexto).

2. Asignar variables a factores:

- Cada variable se asigna al factor donde tiene la carga factorial más alta.

3. Analizar patrones de agrupamiento:

- Las variables con altas cargas en un mismo factor comparten características subyacentes y deben ser interpretadas como parte de un constructo común.

Resultados de la Matriz Rotada

Factor	VARIABLES ASOCIADAS (CARGAS SIGNIFICATIVAS)	Interpretación Conceptual
Componente 1	GN (0.829), R (0.822), NI (0.806), TT (0.501)	Relaciones y valores personales
Componente 2	MP (0.618), SC (0.590), OP (0.549), CPC (0.548), PVP (0.538), GPV (0.494), PCP (0.442)	Gestión organizacional y procesos
Componente 3	SP (0.826), EP (0.819), HP (0.705)	Satisfacción personal y profesional
Componente 4	FC (0.717), PT (0.669), PC (0.647), PD (0.573)	Eficiencia y desempeño operativo
Componente 5	GC (0.760), CLC (0.652), PI (0.615)	Competencias y habilidades críticas
Componente 6	PNC (0.805), PFP (0.801)	Perspectivas financieras y estratégicas

Interpretación Detallada por Componente

1. Componente 1: Relaciones y valores personales

- Variables principales: GN, R, NI, TT.
- Estas variables están asociadas con factores emocionales,

éticos o personales, como valores grupales, responsabilidad y compromiso.

2. Componente 2: Gestión organizacional y procesos

- Variables principales: MP, SC, OP, CPC, PVP, GPV, PCP.
- Representan aspectos relacionados con la gestión y organización, como procedimientos, supervisión y planeación.

3. Componente 3: Satisfacción personal y profesional

- Variables principales: SP, EP, HP.
- Estas variables reflejan la percepción de satisfacción y bienestar en el entorno laboral.

4. Componente 4: Eficiencia y desempeño operativo

- Variables principales: FC, PT, PC, PD.
- Están relacionadas con la eficiencia en el trabajo y la ejecución de tareas específicas.

5. Componente 5: Competencias y habilidades críticas

- Variables principales: GC, CLC, PI.
- Estas variables representan habilidades esenciales, como pensamiento crítico y competencias clave para el desempeño.

6. Componente 6: Perspectivas financieras y estratégicas

- Variables principales: PNC, PFP.
- Se asocian con aspectos estratégicos y financieros, como planificación y previsión.

Conclusión

1. Significado de la rotación Varimax:

- Redistribuye las cargas factoriales de forma que cada variable se asocie claramente con un único factor, mejorando la interpretabilidad.

2. Asociación de variables a factores:

- Las variables han sido asignadas a factores relevantes según sus cargas más altas, lo que permite comprender las

dimensiones subyacentes en los datos.

3. Validez conceptual:

- Los factores identificados tienen sentido teórico y práctico, respaldando la estructura del modelo factorial.

Recomendaciones

1. Etiquetado de Factores:

- Asigna nombres descriptivos a cada componente basándose en las variables con mayores cargas factoriales.

2. Refinamiento del Modelo:

- Considera eliminar variables con cargas factoriales bajas o que no contribuyan claramente a un factor.

3. Validación Posterior:

- Realiza un Análisis Factorial Confirmatorio (AFC) para validar la estructura propuesta y confirmar su ajuste teórico.

Caso: influencia de los factores del entorno de la municipalidad en la gestión del medio ambiente de Puno y Juliaca

OE1. Determinar los factores externos predominantes que influyen en la gestión del medio ambiente en las municipalidades de Puno y Juliaca.

Resolución

Tabla 4

Cargas externas de los factores externos

Factores externos	Cargas externas
1. Factor político legal (FEPL)	
FEPL2. Las decisiones políticas de la región reflejan un compromiso con el medio ambiente	0.640
FEPL3. Las leyes medioambientales locales son claras y efectivas.	0.777

FEPL4. Hay sanciones adecuadas para quienes incumplen las normativas medioambientales.	0.802
2. Factor económico (FEEC)	
FEEC5. La economía local apoya las iniciativas de sostenibilidad y medio ambiente.	0.881
FEEC6. La municipalidad accede a financiamiento externo para programas medioambientales.	0.816
3. Factor sociodemográfico (FESD)	
FESD12. La comunidad participa activamente en programas y actividades medioambientales.	0.723
FESD13. Hay suficientes servicios medioambientales para atender las necesidades demográficas.	0.824
FESD14. El crecimiento poblacional en la ciudad ha afectado la gestión medio ambiental.	0.861
4. Factor tecnológico (FETE)	
FETE7. La Municipalidad ha adoptado tecnologías para la limpieza y sostenibilidad de la ciudad.	0.870
FETE8. La Municipalidad tiene acceso a tecnologías modernas para monitorear el medio ambiente.	0.851
5. Factor ecológico (FEECO)	
FEECO9. Los cambios climáticos naturales han afectado la gestión medioambiental de la ciudad.	0.957
FEECO10. Hay un esfuerzo constante para adaptarse a los cambios ecológicos en la ciudad.	0.536

Las cargas externas de la Tabla evidencian una alta confiabilidad en los indicadores de los factores externos que influyen en la gestión ambiental. La mayoría de los indicadores superan el umbral de 0,7, destacando la carga más alta del factor ecológico (FEECO9) con 0.957, lo que indica una fuerte relación con su constructo latente. Los factores económicos y tecnológicos también presentan cargas robustas, superiores a 0,8, subrayando su representación adecuada en el modelo estructural. Estos resultados sugieren que la gestión ambiental está profundamente afectada por factores interrelacionados; la urgencia de abordar cambios climáticos,

la necesidad de regulaciones efectivas y la importancia del financiamiento son fundamentales para la sostenibilidad de las iniciativas en estas municipalidades.

Tabla 5

Cargas externas de gestión del medio ambiente

Gestión del medio ambiente (GMA)	Cargas externas
GMA22. La municipalidad invierte suficientemente en recursos y personal para la gestión medioambiental.	0.731
GMA23. Estoy satisfecho(a) con la efectividad y ejecución de los programas medioambientales de la municipalidad.	0.816
GMA24. La municipalidad ofrece suficientes y bien mantenidas áreas verdes e infraestructuras de gestión del agua.	0.838
GMA26. Estoy satisfecho con la gestión que realiza la municipalidad respecto a la calidad del aire y del agua en mi localidad.	0.797
GMA27. La municipalidad promueve activamente y valora la participación ciudadana en asuntos medioambientales.	0.820
GMA28. La municipalidad lleva a cabo eficaces programas y campañas de educación y sensibilización medioambiental.	0.830

En la Tabla se observan, elevadas cargas externas del constructo de gestión del medio ambiente (GMA), todas superiores a 0.7, reflejan una alta confiabilidad de los indicadores utilizados en el modelo. En particular, el ítem GMA24 con una carga de 0.838 y GMA28 con 0.830 destacan por su relevancia en la medición del constructo. Estas cargas no solo confirman una fuerte validez convergente, sino que también aseguran que los aspectos clave, como la inversión en recursos, la efectividad de programas, la infraestructura y la calidad ambiental, son representados de manera precisa. Esta consistencia garantiza que el modelo de medida esté adecuadamente

especificado, permitiendo avanzar hacia un análisis estructural robusto sin necesidad de eliminar indicadores.

Tabla 6

Fiabilidad y validez de los factores externos y gestión del medio ambiente

Factores externos	Alfa de Cronbach	Fiabilidad compuesta (ρ_c)	Varianza extraída media (AVE)
1. Factor político legal (FEPL)	0.591	0.785	0.552
2. Factor económico (FEEC)	0.615	0.837	0.721
3. Factor sociodemográfico (FESD)	0.725	0.846	0.648
4. Factor tecnológico (FETE)	0.650	0.851	0.741
5. Factor ecológico (FEECO)	0.421	0.736	0.601
6. Gestión del medio ambiente (GMA)	0.892	0.917	0.650

Los resultados de la Tabla muestran la confiabilidad y validez de los constructos en el modelo de factores externos y gestión del medio ambiente. La confiabilidad compuesta (ρ_c) supera el umbral de 0.7 para todos los constructos, indicando una consistencia interna adecuada. La Varianza Extraída Media (AVE) es superior a 0.5 en todos los casos, lo que sugiere una validez convergente satisfactoria. El factor ecológico muestra la confiabilidad compuesta más baja (0.736), mientras que la gestión del medio ambiente presenta los valores más altos de confiabilidad (0.917) y AVE (0.650). Estos resultados indican que los constructos están bien medidos, especialmente en la gestión del medio ambiente, lo que proporciona una base sólida para el análisis del modelo estructural y la

evaluación de las relaciones entre los factores externos y la gestión ambiental municipal

Tabla 7

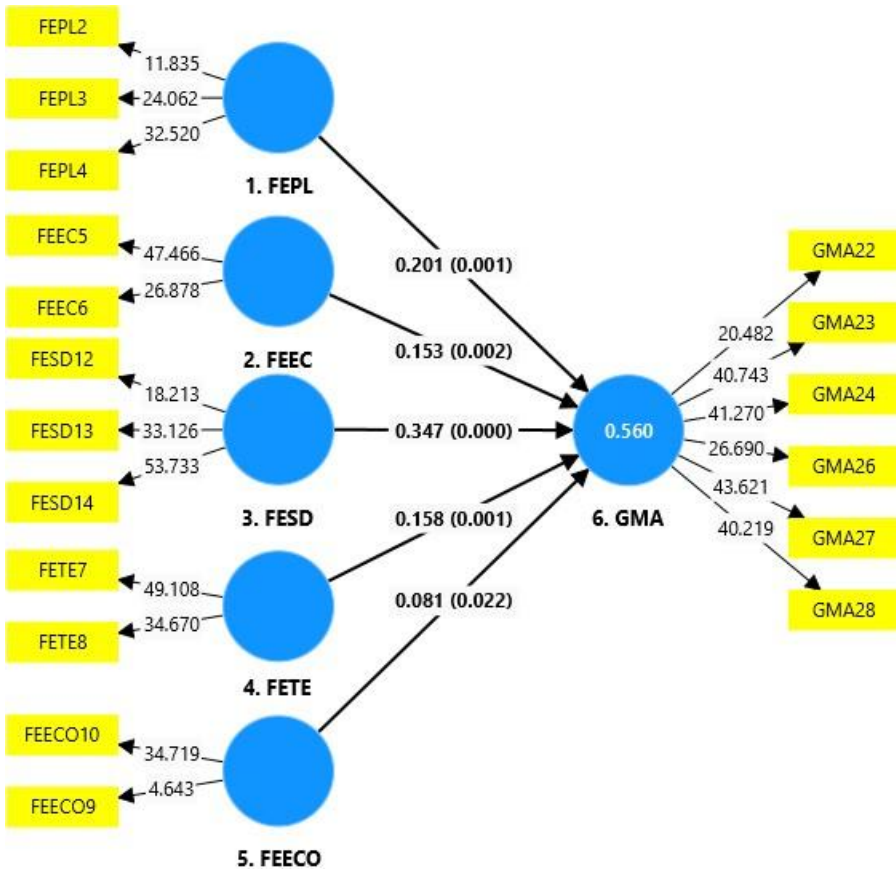
Validez discriminante de los factores externos y gestión del medio ambiente con Criterio de Fornell-Larcker

Constructos	1. FEPL	2. FEEC	3. FESD	4. FETE	5. FEECO	6. GMA
1. FEPL	0.743					
2. FEEC	0.524	0.849				
3. FESD	0.593	0.530	0.805			
4. FETE	0.544	0.524	0.603	0.861		
5. FEECO	0.244	0.361	0.357	0.411	0.775	
6. GMA	0.593	0.554	0.671	0.590	0.374	0.806

En la Tabla 4 se observa la validez discriminante según el criterio de Fornell-Larcker, donde los valores en la diagonal representan la raíz cuadrada del AVE y son mayores que las correlaciones entre constructos, confirmando así la validez discriminante. El factor sociodemográfico muestra la calificación más fuerte con la gestión del medio ambiente (0.671), seguida por el factor político-legal (0.593) y el factor tecnológico (0.590). Lo cual, indica que estos son los factores externos predominantes que influyen en la gestión ambiental municipal. El factor ecológico presenta la calificación más baja con la gestión del medio ambiente (0.374), lo que es sorprendente y merece una investigación más profunda. Estos hallazgos proporcionan una base sólida para la interpretación de las relaciones causales en el modelo estructural de los factores externos y gestión del medio ambiente.

Figura 30

Modelo de los factores de los factores externos y gestión del medio ambiente



El modelo PLS-SEM presentado en la Figura revela las relaciones entre los factores externos y la gestión del medio ambiente (GMA) en las municipalidades. El factor sociodemográfico (FESD) emerge como el más

influyente, con un coeficiente de trayectoria de 0.347 ($p < 0.001$), seguido por el factor político-legal (FEPL) con 0.201 ($p < 0.001$) y el factor económico (FEEC) con 0.153. ($p < 0,002$). Estos resultados indican que los aspectos sociodemográficos, políticos-legales y económicos son los factores externos predominantes que afectan la gestión ambiental municipal. El modelo explica el 56% de la varianza en GMA ($R^2=0.560$), lo que sugiere un poder predictivo moderado. Los indicadores de GMA muestran cargas externas robustas (>0.40), respaldando la validez convergente del constructo.

Acrónimos

Acrónimo Significado

AFC	Análisis Factorial Confirmatorio
AFE	Análisis Factorial Exploratorio
AVE	Varianza Media Extraída (por sus siglas en inglés: <i>Average Variance Extracted</i>)
CFA	<i>Confirmatory Factor Analysis</i> (Análisis Factorial Confirmatorio)
CFI	Índice de Ajuste Comparativo (<i>Comparative Fit Index</i>)
EFA	<i>Exploratory Factor Analysis</i> (Análisis Factorial Exploratorio)
GFI	Índice de Bondad de Ajuste (<i>Goodness-of-Fit Index</i>)
HTMT	Índice de Heterotrait-Monotrait
KMO	Índice Kaiser-Meyer-Olkin
ML	Máxima Verosimilitud (<i>Maximum Likelihood</i>)
PLS-SEM	Modelos de Ecuaciones Estructurales por Mínimos Cuadrados Parciales (<i>Partial Least Squares Structural Equation Modeling</i>)
RMSEA	Raíz del Error Cuadrático Medio de Aproximación (<i>Root Mean Square Error of Approximation</i>)
SEM	Modelos de Ecuaciones Estructurales (<i>Structural Equation Modeling</i>)
SRMR	Raíz Cuadrática Media de los Residuos Estándar (<i>Standardized Root Mean Residual</i>)
TLI	Índice de Tucker-Lewis (<i>Tucker-Lewis Index</i>)
VIF	Factor de Inflación de la Varianza (<i>Variance Inflation Factor</i>)

Bibliografia

- Aguinis, H. (2004). *Regression analysis for categorical moderators*. Guilford Press.
- Almeida, P., & Santos, L. (2023). Innovation and job satisfaction in the technology sector: A SEM approach. *Journal of Business Studies*, 15(3), 201-220.
- Avolio, B. J., & Bass, B. M. (2004). *Multifactor leadership questionnaire*. Mind Garden, Inc.
- Avolio, B. J., & Yammarino, F. J. (2013). *Transformational and Charismatic Leadership: The Road Ahead*. Emerald Group Publishing.
- Bass, B. M. (1990). From transactional to transformational leadership: Learning to share the vision. *Organizational Dynamics*, 18(3), 19-31.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107(2), 238–246.
- Bentler, P. M. (2022). *Structural Equations with Latent Variables*. John Wiley & Sons.
- Bland, J. M., & Altman, D. G. (1997). Statistics notes: Cronbach's alpha. *BMJ*, 314(7080), 572. <https://doi.org/10.1136/bmj.314.7080.572>
- Bollen, K. A. (1989). *Structural Equations with Latent Variables*. New York: Wiley.
- Bollen, K. A. (2019). *Structural Equation Models: Concepts, Issues, and Applications*. Sage Publications.
- Brown, T. A. (2015). *Confirmatory Factor Analysis for Applied Research* (2nd ed.). New York: Guilford Press.

- Brown, T. A. (2019). *Confirmatory Factor Analysis for Applied Research*. Guilford Publications.
- Byrne, B. M. (2013). *Structural equation modeling with AMOS: Basic concepts, applications, and programming* (2nd ed.). Routledge.
- Byrne, B. M. (2016). *Structural Equation Modeling with AMOS: Basic Concepts, Applications, and Programming* (3rd ed.). Routledge.
- Castillo, M., & Alvarado, R. (2023). Employee satisfaction and job stability in tourism companies in Cusco. *Peruvian Journal of Tourism Studies*, 8(1), 45-60.
- Chen, F. F., West, S. G., & Sousa, K. H. (2022). Testing Measurement Invariance of Second-Order Factor Models. *Structural Equation Modeling: A Multidisciplinary Journal*, 29(1), 45-58.
- Cheung, G. W., & Rensvold, R. B. (2017). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural Equation Modeling: A Multidisciplinary Journal*, 20(2), 210-222.
- Chiang, C. F., Chang, J. W., & Han, T. S. (2016). The relationship of transformational leadership, job satisfaction, and organizational commitment in the hotel industry. *International Journal of Hospitality Management*, 55, 112-121.
- Ebrahimi, P., et al. (2022). Social Networks Marketing and Consumer Purchase Behavior: The Combination of SEM and Unsupervised Machine Learning Approaches. *Big Data and Cognitive Computing*, 6(35).
- Fornell, C., Johnson, M. D., Anderson, E. W., Cha, J., & Bryant, B. E. (1996). The American customer satisfaction index: Nature, purpose, and findings. *Journal of Marketing*, 60(4), 7-18.
- García-González, D., & Ruíz, A. (2022). Applications of Structural Equation Modeling in Social Sciences Research. *Journal of Social Research*, 18(2), 215-230.
- George, D., & Mallery, P. (2013). *IBM SPSS Statistics 21 Step by Step: A Simple Guide and Reference*. Pearson.

- Gómez, J., & Martínez, C. (2021). Motivation and turnover intention in Mexican retail workers: A structural model approach. *Mexican Journal of Business Research*, 12(4), 322-340.
- Gonzales, L., Morales, P., & Castillo, J. (2021). Impacto de la satisfacción y el valor percibido en la lealtad del cliente en el sector minorista peruano. *Revista de Marketing y Estrategia Empresarial*, 8(2), 45-61.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis*. Pearson.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2021). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (3rd ed.). Sage.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A Primer on Partial Least Square Equation Modelling (PLS-SEM)*. Sage.
- Hallowell, R. (1996). The relationships of customer satisfaction, customer loyalty, and profitability: An empirical study. *International Journal of Service Industry Management*, 7(4), 27-42.
- Hayes, A. F. (2018). *Introduction to Mediation, Moderation, and Conditional Process Analysis: A Regression-Based Approach* (2nd ed.). Guilford Press.
- Hernández, L., & Reyes, P. (2022). Compensation and organizational commitment in the tourism sector: An SEM analysis. *Journal of Tourism Management*, 25(5), 567-580.
- Hox, J. J., Moerbeek, M., & van de Schoot, R. (2020). *Multilevel Analysis: Techniques and Applications*. Routledge.
- Hoyle, R. H. (2019). *Handbook of Structural Equation Modeling*. Guilford Publications.
- Hu, L. T., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling: A Multidisciplinary Journal*, 6(1), 1-55.


- Hu, L., & Bentler, P. M. (1999). "Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives". *Structural Equation Modeling*, 6(1), 1-55.
- JASP Team. (2020). JASP (Version 0.14) [Computer software]. JASP. <https://jasp-stats.org>
- Jöreskog, K. G. (1970). A general method for estimating a linear structural equation system. *Theoretical and Methodological Issues in Multivariate Analysis*, 19(1), 85–112.
- Kaplan, D. (2008). *Structural Equation Modeling: Foundations and Extensions* (2nd ed.). SAGE Publications.
- Kenny, D. A. (2020). *SEM: Path Analysis and Structural Equation Modeling*
- Kim, H., & Seo, Y. (2022). Machine learning-enhanced structural equation modeling for understanding consumer behavior in e-commerce. *Electronic Commerce Research and Applications*, 50, 101073.
- Kline, R. B. (2015). *Principles and Practice of Structural Equation Modeling* (4th ed.). Guilford Press.
- Kline, R. B. (2016). *Principles and Practice of Structural Equation Modeling* (4th ed.). New York: Guilford Press.
- Kline, R. B. (2021). *Principles and Practice of Structural Equation Modeling* (4th ed.). Guilford Press.
- Kumar, V., & Shah, D. (2004). Building and sustaining profitable customer loyalty for the 21st century. *Journal of Retailing*, 80(4), 317–329.
- Leithwood, K., & Jantzi, D. (2005). Transformational leadership. In B. Davies (Ed.), *The Essentials of School Leadership*. SAGE Publications.
- Little, R. J. A., & Rubin, D. B. (2019). *Statistical analysis with missing data* (3rd ed.). John Wiley & Sons.

- López, M., & Morales, C. (2022). Evaluación de programas sociales y su impacto en la satisfacción de los beneficiarios en Perú. *Revista de Políticas Sociales*, 15(3), 112-128.
- Margalina, V. M., Jiménez-Sánchez, Á., & 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.
<https://doi.org/10.17163/ret.n27.2024.07>
- Martínez, D., & Salazar, L. (2020). Liderazgo y compromiso organizacional en pymes colombianas: Un análisis PLS-SEM. *Revista Colombiana de Psicología Empresarial*, 12(1), 23-39.
- Martínez, P., Gómez, R., & Salcedo, M. (2023). Organizational culture and gender equality perception in Colombian companies. *Journal of Latin American Business Studies*, 14(2), 198-217.
- MDPI. (2024). Structural Equation Modeling in Technology Adoption and Use in the Construction Industry: A Scientometric Analysis and Qualitative Review. *Sustainability*, 16(9), 3824.
<https://doi.org/10.3390/su16093824>
- Meyer, J. P., & Allen, N. J. (1991). A three-component conceptualization of organizational commitment. *Human Resource Management Review*, 1(1), 61-89.
- Muthén, L. K., & Muthén, B. O. (2017). *Mplus User's Guide* (8th ed.). Muthén & Muthén.
- Oliver, R. L. (1999). Whence consumer loyalty? *Journal of Marketing*, 63, 33-44.
- Pérez, L., & González, A. (2020). Cohesión social y percepción de justicia en comunidades urbanas de Chile y Argentina. *Revista Latinoamericana de Estudios Sociales*, 12(2), 205-219.
- Preacher, K. J., & 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.

- Reichheld, F. F. (2003). The one number you need to grow. *Harvard Business Review*, 81(12), 46–55.
- Reichheld, F. F., & Teal, T. (2001). *The Loyalty Effect: The Hidden Force Behind Growth, Profits, and Lasting Value*. Harvard Business School Press.
- Rosseel, Y. (2012). lavaan: An R package for structural equation modeling. *Journal of Statistical Software*, 48(2), 1–36.
- Schreiber, J. B., Nora, A., Stage, F. K., Barlow, E. A., & King, J. (2006). Reporting Structural Equation Modeling and Confirmatory Factor Analysis Results: A Review. *The Journal of Educational Research*, 99(6), 323-338.
- Schumacker, R. E., & Lomax, R. G. (2022). *A Beginner's Guide to Structural Equation Modeling* (5th ed.). Routledge.
- Silva, A., Núñez, J., & Ramos, E. (2022). The impact of transformational leadership on organizational commitment and performance in manufacturing companies. *Peruvian Journal of Organizational Studies*, 10(2), 89-110.
- StataCorp. (2019). *Stata: Release 16 Statistical Software*. StataCorp LLC.
- Sun, Z., & Chen, J. (2024). "Evaluating the Role of SEM in Cross-disciplinary Research". *Technological Advancements Journal*, 15(1), 102-115.
- Tabachnick, B. G., & Fidell, L. S. (2019). *Using Multivariate Statistics* (7th ed.). Pearson.
- Taber, K. S. (2018). The use of Cronbach's alpha when developing and reporting research instruments in science education. *Research in Science Education*, 48(6), 1273-1296.
<https://doi.org/10.1007/s11165-016-9602-2>
- Tavakol, M., & Dennick, R. (2011). Making sense of Cronbach's alpha. *International Journal of Medical Education*, 2, 53-55.
<https://doi.org/10.5116/ijme.4dfb.8dfd>

- Tinto, V. (2012). *Completing college: Rethinking institutional action*. University of Chicago Press.
- Torres, R., Martínez, J., & Valdés, P. (2021). Factores que influyen en la lealtad del cliente en el sector minorista de América Latina: Un análisis a través del Modelo de Ecuaciones Estructurales. *Journal of Business Research*, 10(4), 325-340.
- Vargas, M., & Rojas, J. (2022). Evaluación de la calidad educativa en instituciones peruanas de educación superior mediante SEM y AFC. *Revista de Investigación Educativa de Perú*, 29(3), 215-230.
- Vásquez, D., & Rojas, J. (2024). The impact of organizational support and equality policies on gender equality perception in Peruvian companies. *Peruvian Journal of Social Sciences*, 9(3), 255-273.
- Wawrosz, P., & Jurásek, M. (2021). Developing Intercultural Efficiency: The Relationship between Cultural Intelligence and Self-Efficacy. *Social Sciences*, 10(8), 312. Enlace al artículo.
- Yi, J., & Chen, L. (2024). “*Exploring the Applications of SEM in Business and Management Studies*”. *International Journal of Business Research*, 29(3), 152-168.
- Yukl, G. (2013). *Leadership in Organizations* (8th ed.). Pearson Education.
- Zhou, Q., Huang, X., & Li, S. (2023). Integrating structural equation modeling and machine learning for big data analytics in business research. *Journal of Business Research*, 152, 104-118.

Autores



Manuel Anchapuri Q.

Doctoris Scientiae en: Administración y Contabilidad.

Magister Scientiae en contabilidad y administración.

Licenciado en Administración de la Universidad Nacional del Altiplano

Segunda especialidad en Docencia Universitaria, Docente de la E.P. de Administración y de la Escuela de Post grado de la UNA-Puno; Past decano del colegio de Administradores y Miembro del Consejo Directivo Nacional como presidente nacional del Capitulo profesional de Administración de la comercialización y marketing.

manchapuri@unap.edu.pe



Héctor Efraín Flores Ortega

Ingeniero Economista, con Grado de Maestría en Contabilidad y Administración, Mención Administración y Finanzas. Consultor en Planificación Estratégica, Proyectos de Inversión Pública y Proyectos de Inversión Privada. Docente Universitario de Pregrado y Postgrado, en Universidades Públicas y Privadas en la Región de Puno.



Fredy Quispe Gómez

Doctoris Scientiae en : Administración, Magister Scientiae en: Contabilidad y Administración con estudios de Maestría en Investigación y Docencia Universitaria, Licenciado en Administración de Empresas; Docente Universitario Universidad Nacional del Altiplano Escuela profesional de Administración, Delegado ante el consejo Directivo nacional del Colegio de Licenciados en Administración; CEO y Fundador CIEE Cámara internacional de Empresarios y emprendedores, y Universidad Internacional empresarial- de la CIEE



Carlos Fuentes Guizado

Magister en Gestión Pública y Contador Público Colegiado y Bach. Ingeniería de sistemas e Informática; Docente E.P de Administración de la Universidad Nacional Micaela Bastidas de Apurímac, docente E.P de Contabilidad de la Universidad Tecnológica de los Andes, Gerente de la Cooperativa de Ahorro y Crédito Micaela Bastidas, Gerente de Planificación y Presupuesto de la Municipalidad Provincial de Chincheros, director de Recursos Humanos Universidad Nacional Micaela Bastidas de Apurímac.



Alberto Catachura Vilca

Doctor en Administración; Magister Scientiae en Gestión y Desarrollo de turismo rural; Licenciado en Turismo; Docente Ordinario de la Universidad Nacional del Altiplano; Líder en Gestión Pública; Reconocido por la Prensa del Perú con pluma de oro



ISBN: 978-612-03-0367-2



En un mundo donde los datos se han convertido en el eje central de la toma de decisiones, los **Modelos de Ecuaciones Estructurales (SEM)** emergen como una herramienta poderosa y versátil para explorar relaciones complejas entre variables latentes y observadas. Este libro, escrito por un equipo con amplia experiencia en investigación y docencia, ofrece una guía clara y accesible para comprender y aplicar los SEM en diversos contextos científicos y profesionales.

Descubre el poder de los Modelos de Ecuaciones Estructurales y lleva tu investigación al siguiente nivel.