



**Análisis de Ecuaciones Estructurales:
conceptos, etapas de desarrollo y un ejemplo de aplicación**

Dr. Marcos Cupani

Resumen

El modelo de ecuaciones estructurales (Structural Equation Modeling, SEM) es una técnica que combina tanto la regresión múltiple como el análisis factorial. Permite al investigador no solo evaluar las muy complejas interrelaciones de dependencia sino también incorporar los efectos del error de medida sobre los coeficientes estructurales al mismo tiempo. Debido al crecimiento y la utilidad de esta técnica en la actualidad, se propone a continuación una introducción de los seis pasos recomendados para poder aplicar un SEM: especificación, identificación, estimación de parámetros, evaluación del ajuste, reespecificación del modelo e interpretación de resultados. Con el objetivo de ayudar al lector a comprender esta técnica, se propone un ejemplo práctico de aplicación.

Palabras clave: Modelo de ecuaciones estructurales - estimación de parámetros -índices de ajuste

Introducción

En la actualidad los investigadores para poder captar de forma adecuada la complejidad de los fenómenos psicológicos utilizan métodos multivariados. El número de técnicas multivariadas que se utilizan en las ciencias sociales y especialmente en psicología es bastante amplio. Entre las más comunes se destacan la regresión múltiple, el análisis factorial, el análisis multivariante de la varianza, y el análisis discriminante. Cada una de estas técnicas es una poderosa herramienta a la hora de tratar un amplio abanico de cuestiones prácticas y teóricas, aunque poseen una limitación común: sólo pueden examinar una relación al mismo tiempo. Incluso las técnicas que tienen en cuenta varias variables dependientes, como el análisis multivariante de la varianza, sigue representando solo una única relación entre variables dependiente e independiente

(Hair, Anderson, Tatham y Black, 2001).

El *modelo de ecuaciones estructurales* (Structura! Equation Modeling, SEM) permite examinar simultáneamente una serie de relaciones de dependencia, y es particularmente útil cuando una variable dependiente se convierte en variable independiente en ulteriores relaciones de dependencia. Además, muchas de las mismas variables afectan a cada una de las variables dependientes, pero con efectos distintos (Hair, et al, 2001). Se puede pensar que el modelo de ecuaciones estructurales es una extensión de varias técnicas multivariadas como la regresión múltiple y el análisis factorial (Kahn, 2006). Sin embargo, posee algunas características particulares que lo diferencian de las otras técnicas multivariadas. Una de las diferencias es la capacidad de estimar y evaluar la relación entre constructos no observables, denominados generalmente *variables latentes*. Una variable latente es un constructo supuesto (inteligencia, por ejemplo) que solo puede ser medido mediante variables observables (test de inteligencia, por ejemplo). En comparación con otras técnicas de análisis donde los constructos pueden ser representados con una única medición (puntajes brutos de un test, por ejemplo) y el error de medición no es modelado, el SEM permite emplear múltiples medidas que representan el constructo y controlar el error de medición específico de cada variable. Esta diferencia es importante ya que el investigador puede evaluar la validez de cada constructo medido.

Otra característica particular es que para interpretar los resultados de SEM se deben evaluar cuidadosamente varias pruebas estadísticas y un conjunto de índices que determinan que la estructura teórica propuesta suministra un buen ajuste a los datos empíricos. Este ajuste se verifica si los valores de los parámetros estimados reproducen tan estrechamente como sea posible la matriz observada de covarianza (Kahn, 2006).

Sin lugar a duda, el principal aporte que realiza el SEM es que permite a los investigadores evaluar o testear modelos teóricos, convirtiéndose en una de las herramientas más potentes para el estudio de relaciones causales sobre datos no experimentales cuando estas relaciones son de tipo lineal (Kerlinger, y Lee, 2002). No obstante, estos modelos nunca prueban la causalidad. En realidad, solo ayudan a seleccionar hipótesis causales relevantes, eliminando aquellas no sustentadas por la evidencia empírica. Así, los modelos causales son susceptibles de ser estadísticamente rechazados si se contradicen con los datos. Por lo tanto, el investigador nunca debe olvidar que el verdadero valor de esta técnica es especificar complejas relaciones entre

variables *a priori* y luego evaluar cuántas de esas relaciones se representan en los datos recolectados empíricamente (Weston y Gore, 2006).

El principal impulso en la utilización de estos métodos y técnicas multivariadas ha sido el desarrollo de las computadoras. En la actualidad, se dispone de una variedad de programas computarizados que simplifican enormemente estas tareas y permiten la realización de análisis cada vez más poderosos y sofisticados. Existen al menos tres software altamente reconocidos y que actualmente están en uso. El primero de ellos es el LISREL (Linear Estructural Relations) que fue creado por

Joreskog y sus colaboradores (Joreskog y Sorbom, 1996) para establecer y analizar estructuras de covarianza. Las primeras versiones de este programa requerían del establecimiento de planteamientos muy difíciles para el usuario que no tenía conocimiento matemático profundo. Luego, el programa llamado EQS (Structural Equation Modeling Software) que fue desarrollado por Bentler (1995) presenta planteamientos y símbolos del modelo más fáciles de comprender. Finalmente, el programa Análisis de Estructuras Momentáneas (Analysis of Moment Structures, AMOS) que fue creado por Arbuckle (2003), permite al usuario que especifique, vea y modifique el modelo de estructura *gráficamente* por medio del uso de herramientas gráficas sencillas. Cada uno de estos programas ha logrado que los investigadores usen con mayor facilidad el modelo de ecuaciones estructurales.

Debido al crecimiento y la utilidad de esta técnica en la actualidad, se propone a continuación una introducción de los principales conceptos del SEM. Para poder exponer con mayor claridad la utilidad del SEM, se utilizará un simple ejemplo que ayudará al lector a comprender esta técnica.

1. La función de la teoría en los modelos de Ecuaciones Estructurales

A lo largo de la exposición del SEM, nos referiremos a la necesidad de una justificación teórica para la especificación de las relaciones de dependencia, modificaciones de las relaciones propuestas y muchos otros aspectos de la estimación de un modelo. Una *teoría* puede definirse como un conjunto sistemático de relaciones que ofrecen una explicación exhaustiva y consistente de un fenómeno (Hair, et al 2001). La necesidad de un modelo teórico para guiar el proceso de estimación se hace especialmente crítica cuando se hacen modificaciones del modelo. Dada la flexibilidad del SEM, las oportunidades de *sobreajustar* el modelo son muy elevadas, por lo tanto, es importante

resaltar la necesidad de la justificación teórica antes que los resultados empíricos.

Existen tres estrategias que un investigador puede adoptar en la utilización de sistemas de ecuaciones estructurales: (1) la estrategia de modelización confirmatoria, (2) la estrategia de modelos rivales, y (3) la estrategia de desarrollo del modelo. La aplicación más directa de los modelos de ecuaciones estructurales es una estrategia de modelización confirmatoria, donde el investigador especifica un modelo aislado y el modelo de ecuaciones estructurales se utiliza para evaluar su significación estadística. La investigación ha demostrado que las técnicas desarrolladas para evaluar los modelos de ecuaciones estructurales tienen un sesgo confirmatorio. Por lo tanto, aunque el modelo propuesto presente un ajuste aceptable, el investigador no ha probado el modelo propuesto, sino que solo ha confirmado que es uno de los varios modelos posibles.

La estrategia de modelos rivales permite evaluar el modelo estimado con modelos alternativos. En muchas ocasiones el investigador se encuentra con modelos alternativos para representar una misma situación sin conocer cuál proporciona un nivel de ajuste mejor. Esta estrategia proporciona las líneas básicas para realizar esta comparación y seleccionar el más idóneo. Un ejemplo habitual de modelos rivales es el proceso de evaluación factorial de invarianza, la igualdad de modelos de factor entre grupos. Otro ejemplo refiere a los modelos anidados, en el que el número de constructos e indicadores permanecen constantes, pero el número de relaciones estimadas cambian. Finalmente, la estrategia de desarrollo del modelo difiere de las dos anteriores estrategias en que aunque se propone un modelo, el propósito del esfuerzo de modelización es mejorarlo a través de modificaciones de los modelos de medida y/o estructurales. El investigador que sigue esta estrategia intenta reespecificar un modelo básico para encontrar uno nuevo.

2. Modelo de Medida y Estructural

En el modelo de ecuaciones estructurales se pueden identificar dos componentes principales: (a) un modelo de medida que representa las relaciones de las variables latentes (o constructos) con sus indicadores (o variables empíricas), y (b) el modelo estructural donde se describe la interrelación entre los constructos. El *modelo de medida* permite al investigador usar varias variables (indicadores), para una única variable latente dependiente o independiente. El objetivo fundamental del modelo de medida es corroborar la idoneidad de los indicadores seleccionados en la medición de los

constructos de interés, es decir, que el investigador evalúe qué tan bien las variables observadas combinan (cavarían o correlacionan) para identificar el constructo hipotétizado. En el caso de que los indicadores propuestos correlacionen débilmente entre sí, se puede considerar que el investigador ha especificado el modelo erróneamente o que hay un desacierto en las presuntas relaciones entre las variables (Weston y Gore, 2006). En la figura 1 se propone un ejemplo del modelo de medida.

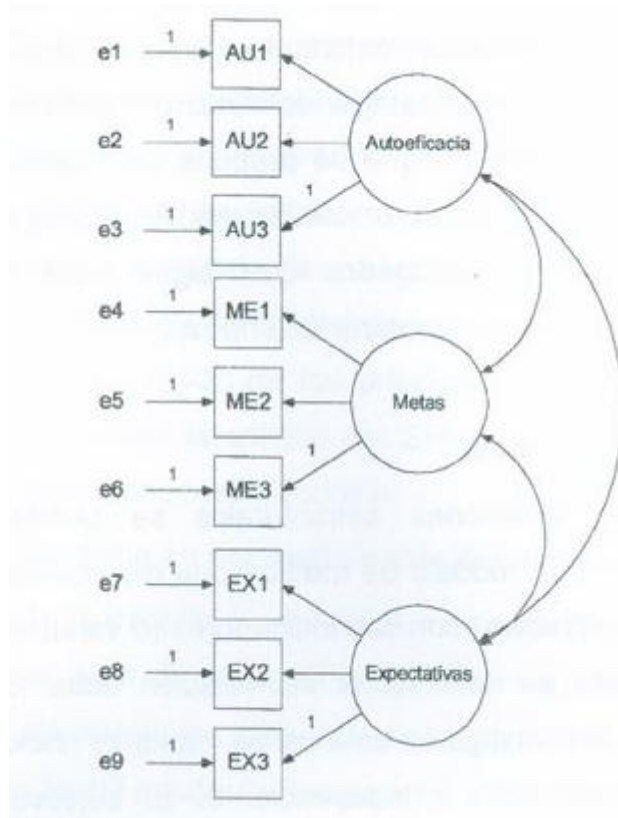


Figura 1. Análisis Factorial Confirmatorio de tres mediciones.

En este ejemplo el modelo de medida está compuesto por tres variables latentes y nueve indicadores. La literatura sugiere (por ejemplo, Bollen, 1989) que lo ideal sería que cada uno de los indicadores fuesen medidas independientes (test o cuestionarios), que en combinación son representativos del constructor propuesto. No obstante, una alternativa muy utilizada consiste en *parcelarizar* los ítems de una misma escala. Este método consiste en agrupar los ítems de una misma escala en subtest de ítems de forma aleatoria (Hall, Snell & Singer Foust, 1999). Este tipo de estrategia, utilizada en este ejemplo, permite incluir múltiple indicadores de un mismo constructor al carecer de

múltiples medidas (escalas) del mismo constructor. No obstante, sin importar que metodología se utilice, los usuarios del SEM deben considerar que los mejores indicadores serán aquellas escalas con altos índices de confiabilidad ($\alpha \geq 0,80$), y aquellos ítems que presenten pesos factoriales más altos en sus respectivas escalas o cuestionarios.

El *modelo estructural* es el modelo *guía*, que relaciona variables independientes y variables dependientes. En tales situaciones, la teoría, antes que la experiencia u otras directrices, permitirá al investigador distinguir qué variables independientes predicen cada variable dependiente. En la figura 2 se presenta parte del modelo de rendimiento académico propuesto por la Teoría Social-Cognitiva del Desarrollo de Carrera (Lent, Brown & Hackett, 1994), donde las creencias de autoeficacia afectan al nivel de rendimiento directamente, e indirectamente a través de las metas de rendimiento. El modelo también incorpora el rol de las expectativas de resultados como variable moderadora entre las creencias de autoeficacia y las metas de rendimiento. Finalmente, la calidad del rendimiento logrado va a depender, en gran parte, de las metas de rendimiento que el individuo establezca.

En la figura 2, las creencias de autoeficacia, expectativas de resultado, metas de rendimiento y rendimiento son variables latentes, representadas con elipses. Las variables medidas (indicadores) son representadas por rectángulos. Cada una de las variables medidas o latentes pueden ser exógenas (independientes) o endógenas (dependientes). En la figura 2, todos los indicadores (ejemplo, AU1, ME1, etc.) son endógenos porque son dependientes (son precedidos) por sus respectivas variables latentes. De las cuatro variables latentes, sólo la variable creencias de autoeficacia es exógena (no es precedida por ninguna otra variable), y todas las otras variables latentes son dependientes de alguna otra variable. Uno de los supuestos fundamentales del SEM es que las variables dependientes tienen cierta variación no explicada por la variable latente que es atribuible al error de medición. Por lo tanto, la varianza del error debe ser modelada. La variación del error es especificada mediante un indicador del error que generalmente es representado con la letra e . el error asociado a variables latentes dependientes se representa con la letra D .

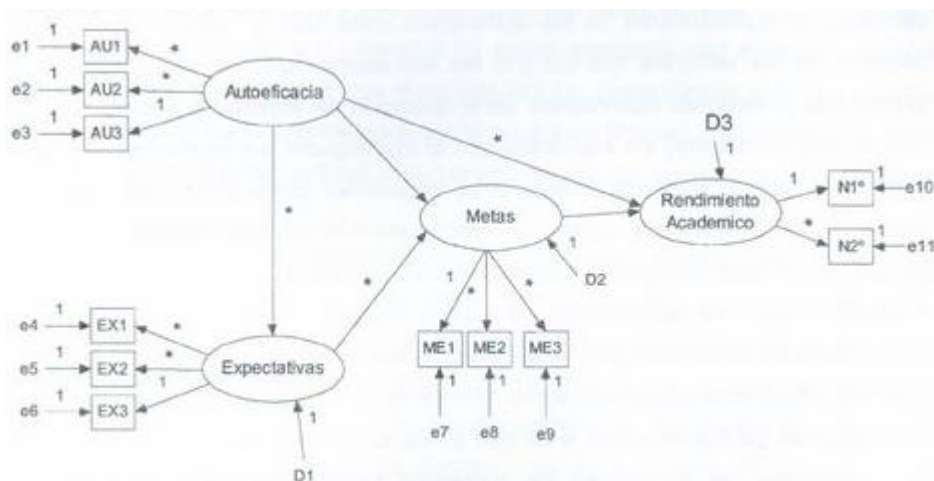


Figura 2. Modelo estructural del Modelo de rendimiento académico propuesto por la Teoría Social Cognitiva del Desarrollo de Carrera (Lent, Brown & Hackett, 1994).

Otra característica del SEM es que las relaciones entre las variables latentes pueden ser de tres tipos: covarianza, efectos directos o efectos indirectos (mediadores). Covarianza es análoga a la correlación y es definida como la relación no-direccional entre las variables (latentes) independientes. Esta relación se representa mediante una flecha de doble punta. Como los autores de este modelo no proponen una relación no-direccional entre las variables, en la figura 2 no se especificó una covarianza entre las variables latentes. El efecto directo es la relación entre la variable latente y la medida (indicador) o entre dos variables latentes, similar a lo que se observa en el análisis de regresión múltiple. Se indica esta relación mediante una flecha unidireccional (por ejemplo, entre autoeficacia y expectativas de resultados) que implica direccionalidad entre las variables, aunque no debe interpretarse como causalidad. Un efecto indirecto es la relación entre una variable latente independiente y una variable latente dependiente cuando su efecto es mediado por una o más variables latentes (Barón & Kenny, 1986). En la figura 2, las creencias de autoeficacia tienen un efecto directo sobre el rendimiento académico, y a su vez, un efecto indirecto sobre el rendimiento académico mediado por las metas de rendimiento.

3. Pasos en la Modelización de Ecuaciones Estructurales

Los principales especialistas en el SEM consideran seis pasos a seguir para aplicar esta técnica: especificación, identificación, estimación de parámetros, evaluación del ajuste,

reespecificación del modelo e interpretación de resultados (Kaplan, 2000; Kline, 2005). Además, incluyen un apartado a considerar: el análisis de la matriz de datos.

4.1. Especificación del modelo

En esta fase el investigador aplica sus conocimientos teóricos del fenómeno estudiado al planteamiento de las ecuaciones matemáticas relativas a los efectos causales de las variables latentes y a las expresiones que las relacionan con los indicadores o variables observables. Esta distinción es importante porque cualquier relación entre variables, sin especificar por el investigador, se asume que es igual a cero. En la figura 2, la relación directa entre expectativa de resultados y el rendimiento académico es igual a cero, aunque la relación entre estas dos variables es mediada por las metas de rendimiento. La especificación errónea en este modelo existirá si el mediador (metas de rendimiento) no explica completamente la relación entre las expectativas de resultados y el rendimiento académico. Además, en esta etapa, se formulan enunciados sobre el conjunto de parámetros, decidiendo entre los que serán libres para ser estimados o fijos, a los que se les asignará un valor dado, normalmente cero. Asimismo, se especifican los supuestos estadísticos sobre las fuentes de variación y en concreto sobre la forma de distribución conjunta, que en la mayoría de las técnicas empleadas se considera normalidad multivariante. La claridad del modelo viene determinada por el grado de conocimiento teórico que posea el investigador sobre el tema de estudio. En efecto, si la información es poco exhaustiva o detallada, la asignación de los parámetros será confusa *a priori*, por lo que el investigador deberá realizar luego diversas modificaciones, contemplando principalmente los aspectos teóricos.

4.2. Identificación del Modelo

Si el modelo teórico es correcto, se procede a la identificación del modelo, en donde debemos asegurar que pueden ser estimados los parámetros del modelo. El modelo está identificado si todos los parámetros lo están, es decir, si existe una solución única para cada uno de los parámetros estimados. Determinar si un modelo está identificado debe analizarse antes de la recolección de datos, verificando que al menos se dispone para cada parámetro de una expresión algebraica que lo exprese en función de las varianzas y covarianzas muestrales. Existe una serie de reglas generales aplicables para identificar un modelo, una de ellas es la regla de los grados de libertad. Los investigadores

calculan el número de grados de libertad (gl) en un modelo utilizando la siguiente fórmula: $(\text{Número de variables observadas} \times [\text{número de variables} + 1]) / 2$. Se espera que los grados de libertad del modelo deban ser mayores o iguales a cero. Esto corresponde a lo que se denomina como modelo identificado o modelo sobreidentificado. Un *modelo identificado* tiene exactamente cero grados de libertad ($gl=0$). Aunque esto ofrece un ajuste perfecto del modelo, la solución no tiene interés puesto que no se puede generalizar. Un *modelo sobreidentificado* es el objetivo de todos los modelos de ecuaciones estructurales. Tiene más información en la matriz de datos que el número de parámetros a estimar, lo que significa que tiene un número positivo de grados de libertad ($gl>0$). Al igual que otras técnicas multivariantes, el investigador se esfuerza por conseguir un ajuste aceptable con el mayor grado de libertad posible. Esto asegura que el modelo sea tan generalizable como sea posible. Finalmente, un *modelo infraestimado* tiene grados de libertad negativo ($gl<0$), lo que significa que se intentan estimar más parámetros de los que permite la información disponible.

Al aplicar esta revisión de identificación al modelo de la Figura 2, se evidencia que hay 11 variables observadas (66 elementos conocidos en la matriz de covarianza; $(11 \times [11+1]) / 2 = 66$), y hemos especificado 10 parámetros para ser estimados que están destacados con asteriscos. Restando los 10 parámetros a estimar de los 66 parámetros conocidos revela que para este modelo hay 56 grados de libertad. En resumen, mientras más grados de libertad, más parsimonioso es el modelo. Así, cuando un modelo es parsimonioso se ajusta bien a los datos, el investigador puede demostrar que las asociaciones entre variables observadas y latentes son más importantes.

4.3. Evaluación de la calidad de la base de datos

Previo al análisis, es recomendable examinar todas las variables a los fines de evaluar la calidad de la base de datos. El primer tema a tratar es el *tamaño de la muestra*, ya que es uno de los aspectos donde menos consenso hay entre los especialistas. Algunos autores (por ejemplo, Kline, 2005) consideran que una muestra adecuada debería tener entre 10 a 20 participantes por parámetro estimado. Otros sugieren (MacCallum, Browne, y Sugawara, 1996) que el tamaño de la muestra depende del poder estadístico deseado, de las hipótesis nulas a evaluar y de la complejidad del modelo (cuando el modelo es más complejo, mayor tamaño de la muestra). Por su parte, Jackson (2003) sugiere que la confiabilidad de las medidas observadas y el número de indicadores por

factor determinan el ajuste del modelo, y controlando estos factores, el tamaño de la muestra mínima recomendable es 200 sujetos para cualquier SEM.

Otro aspecto a tener en cuenta es la *multicolineidad* entre las variables, donde variables altamente correlacionadas son consideradas redundantes. Una pauta para verificar si existe multicolineidad entre las variables es mediante una correlación y bivariada, donde valores superiores a $r = 0,85$ pueden señalar potenciales problemas (Kline, 2005). Cuando se observa que dos variables están altamente correlacionadas, la solución más práctica es retirar una de ellas del modelo. Los investigadores también deben examinar la existencia de casos con puntuaciones marginales (outliers) univariados y multivariados. Cuando los puntajes de un sujeto son extremos en solo una variable, se denomina casos atípicos univariados, pero cuando presentan puntajes extremos en más de una variable, se denominan casos atípicos multivariados. En Tabachntek & Fidell (2001) se presenta una exposición clara de cómo tratar los casos

Finalmente, los estadísticos utilizados en SEM asumen que la distribución multivariada está normal. Violar esta suposición es problemático y afecta la precisión de las pruebas estadísticas. Sin embargo, evaluar la distribución normal multivariada generalmente es poco práctico, ya que esto implica el examen de un número infinito de combinaciones lineales. Una solución a este problema es examinar la distribución de cada variable observada. Para determinar si existe normalidad univariada, el investigador debe examinar la asimetría y curstosis de cada variable observada, donde valores entre +1.00 y -1.00 se considerarán excelentes, mientras que valores inferiores a 1.60, adecuados (George & Mallery, 2001). Sin embargo, un método que incrementa la distribución de la normalidad es la transformación de los datos. Los métodos más comunes de transformación son la raíz cuadrada, el logaritmo, y el inverso. Eliminar o transformar los casos atípicos univariados o multivariados aumenta la distribución normal de los datos.

4.4. Estimación de parámetros

La estimación implica determinar los valores de los parámetros desconocidos y su respectivo error de medición. Como en la regresión múltiple, los investigadores estiman los coeficientes no estandarizados y estandarizados de los parámetros. Para estimar los parámetros desconocidos, los investigadores utilizan programas especiales para el SEM, como el LISREL (Jóreskog & Sorbom, 1996), AMOS (Arbuckle, 2003), y el EQS

(Bentler, 1995). Una de las técnicas ampliamente empleada en la mayoría de los programas informáticos para la estimación de modelos estructurales, es el de máxima verosimilitud (MV), que es eficiente y no sesgada cuando se cumplen los supuestos de normalidad multivariada. La sensibilidad de este método de estimación a la no normalidad, creo que genera la necesidad de técnicas de estimación alternativas, como el método mínimos cuadrados ponderados (WLS), mínimos cuadrados generalizados (GLS) y asintóticamente libre de distribución (AGL). La técnica AGL ha recibido particular atención debido a su insensibilidad a la no normalidad de los datos, pero este método exige un número considerable de casos ($N=500$ o mas).

4.5. Evaluación del ajuste e interpretación

La etapa de diagnóstico de la bondad del ajuste se refiere a la exactitud de los supuestos del modelo especificado para determinar si el modelo es correcto y sirve como aproximación al fenómeno real, precisando así su poder de predicción. Las medidas de calidad del ajuste pueden ser de tres tipos: (1) medidas absolutas del ajuste, que evalúan el ajuste global del modelo, (2) medidas del ajuste incremental, que comparan el modelo propuesto con otros modelos especificados por el investigador, o (3) medidas del ajuste de parsimonia, que *ajustan* las medidas de ajuste para ofrecer una comparación entre modelos con diferentes números de coeficientes estimados, siendo su propósito determinar la cantidad del ajuste conseguido por cada coeficiente estimado (Hair et al., 2001).

La literatura recomienda emplear múltiples indicadores para evaluar el ajuste del modelo (Hu & Bentler, 1995). Entre los más utilizados podemos destacar el estadístico chi-cuadrado, la razón de chi-cuadrado sobre los grados de libertad (CMIN/DF), el cambio en chi-cuadrado entre los modelos alternativos, el índice de ajuste comparativo (CFI), el índice de bondad de ajuste (GFI), y el error cuadrático medio de aproximación (RMSEA). Los valores de estos estadísticos de bondad del ajuste (CFI, GFI) varían por lo general entre 0 y 1, con 1 indicando un ajuste perfecto. Valores superiores a 0,9 sugieren un ajuste satisfactorio entre las estructuras teóricas y los datos empíricos, y valores de 0,95 o superiores, un ajuste óptimo. El chi cuadrado debe ser no significativo para indicar un buen ajuste de los datos. Esto es así porque un valor significativo de χ^2 implica que la estructura del modelo teórico propuesto es significativamente diferente de la indicada por la matriz de covarianza de los datos. No obstante, este último

estadístico es sensible al tamaño muestral y debe interpretarse con precaución. Usualmente se interpreta también la razón de chi cuadrado sobre los grados de libertad, con valores inferiores a 2 indicando un buen ajuste. Cuando se comparan diferentes modelos teóricos, la reducción significativa en chi cuadrado de un modelo respecto a otro también sugiere un ajuste más adecuado a los datos (Tabachnick & Fidell, 2001). El índice RMSEA es considerado óptimo cuando sus valores son inferiores a 0,06 (Hu & Bentler, 1995). Finalmente, además de considerar el ajuste del modelo, debe prestarse atención a la significación de los parámetros estimados que son análogos a los coeficientes de regresión. Al igual que en el análisis de regresión, un modelo que se ajusta bien a los datos, pero que posee pocos coeficientes significativos, no tendría mucho sentido.

4.6. Reespecificación del modelo

En raras ocasiones el modelo propuesto es el que mejor se ajusta. En consecuencia, el investigador normalmente busca métodos para mejorar el ajuste del modelo y/o su correspondencia con la teoría subyacente. En tal caso, puede iniciar la reespecificación del modelo, el proceso de añadir o eliminar los parámetros estimados del modelo original. Antes de tratar algunos enfoques para identificar las modificaciones del modelo, es aconsejable hacer tales modificaciones con cuidado y considerando las justificaciones teóricas antes que las empíricamente deseables. Si se realizan modificaciones, el modelo debería tener una validación cruzada (es decir, estimado sobre un conjunto distinto de datos) antes de que el modelo modificado sea aceptado.

Para realizar una reespecificación se deben examinar los *índices de modificación*. El valor del índice de modificación corresponde aproximadamente a la reducción en el chi-cuadrado que se produciría si el coeficiente fuera estimado. Un valor de 3,84 o superior sugiere que se obtiene una reducción estadísticamente significativa en el chi-cuadrado cuando se estima el coeficiente (Hair et al., 2001). El investigador también puede examinar la *matriz residual* de la matriz de las predicciones de la covarianza y correlación, donde los valores residuales mayores que 2,58 se consideran estadísticamente significativos a nivel de 0,05. Los residuos significativos indican un error de predicción sustancial para un par de indicadores.

Conclusión

En la actualidad cada vez es más fácil para los investigadores el uso de los programas computacionales como el LISREL, EQS, y AMOS que permiten realizar los complejos análisis matemáticos que requieren las Ecuaciones Estructurales. Sin embargo, el rápido acceso a los programas computacionales fáciles de usar podría conducir al uso inapropiado del SEM. En el modelamiento estructural las implicaciones de una teoría se integran en un modelo que refleja la teoría y sus implicaciones: se incluyen variables latentes, se evalúan sus relaciones y efectos, y se somete a la estructura completa de relaciones a una comprobación simultánea. Las pruebas se basan en la congruencia del modelo hipotetizado con los datos obtenidos. No es de sorprender que los investigadores experimenten fallas lógicas, técnicas y teóricas. De hecho, resulta sorprendente que los modelos sean comprobados exitosamente, dada la complejidad e incluso delicadeza de la tarea (Kerlinger y Lee, 2002). A pesar de las dificultades, no caben dudas de que el análisis de ecuaciones estructurales y los programas computacionales que los implementan son altamente valiosos y realizan una contribución útil a la investigación científica del comportamiento. Bajo ciertas condiciones y limitaciones, el sistema es un medio poderoso de comprobación de explicaciones psicológicas y sociológicas de complejos fenómenos humanos y sociales, y, hasta el momento, es uno de los caminos más parsimoniosos para lograr las metas de las ciencias del comportamiento.

Referencias bibliográficas

- Arbuckle, J. L. (2003). *Amos user's guide*. Chicago: SmallWaters.
- Barón, R. M., & Kenny, D. A. (1986). The moderator-mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, 51, 1173-1182.
- Bentler, P. M. (1995). *EQS structural equations program manual*. Encino, CA: Multivariate Software.
- Bollen, K. A. (1989). A new incremental fit index for general structural equation models. *Sociológica! Methods & Research*, 17, 303-316.
- George, D. & Mallery, M. (2001). *Using SPSS for Windows step by step: a simple guide and reference*. Boston, MA: Allyn & Bacon.
- Hair, J.F.; Anderson, R.E.; Tatham, R.L. y Black, W. (1995). *Análisis Multivariante*. 5a

edición. Prentice Hall.

- Hall, R. J., Snell, A. F., & Singer Foust, M. (1999). ítem parceling strategies in SEM: Investigating the subíle effects of unmodeled secondary constructs. *Organizational Research Methods*, 2, 233-256.
- Hu, L.-T., & Bentler, P. M. (1998). Fit índices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods*, 3, 424-453.
- Jackson, D. L. (2003). Revisiting sample size and number of parameter estimates: Some support for the N:q hypothesis. *Structural Equation Modeling*, 10, 128- 141.
- Joreskog, K. G., & Sórbon, D. (1996). *LISREL 8: User's reference guide*. Chicago: Scientific Software International.
- Kahn, J. H. (2006). Factor analysis in Counseling Psychology research, training and practice: Principles, advances and applications. *The Counseling Psychologist*, 34, 1-36.
- Kaplan, D. (2000). *Structural equation modeiing: Foundations and extensions*. Newbury Park, CA: Sage.
- Kerlinger, F. & Lee, H. (2002). *Investigación del comportamiento. Métodos de investigación en las ciencias sociales*. México: McGraw-Hill.
- Kline, R. B. (2005). *Principies and practice of structural equation modeiing* (2nd Ed.). New York: Guilford.
- Lent, R. Brown, S. & Hackett, G. (1994). Toward a unifying social cognitive theory of career and academic interest: Choice and performance. *Journal of Vocational Behavior*, 45, 79-122.
- MacCallum, R. C, Browne, M. W., & Sugawara, H. M. (1996). Power analysis and determination of sample size for covariance structure models. *Psychological Methods*, 1, 130-149.
- Tabachnick, B. & Fidell, L. (2001). *Using multivariate statistics*. New York: Harper & Row.
- Weston, R. and Gore Jr., P. A., (2006). A Brief Guide to Structural Equation Modeiing. *The Counseling Psychologist*, 34; 719-751.