



METODOLOGÍA DE INVESTIGACIÓN EN EDUCACIÓN MÉDICA

Introducción a los modelos de ecuaciones estructurales

Abigail Patricia Manzano Patiño*

Unidad de Estadística y Análisis de datos, Coordinación de Desarrollo Educativo e Innovación Curricular, Universidad Nacional Autónoma de México, Ciudad de México, México

Recibido el 15 de septiembre de 2017; aceptado el 15 de noviembre de 2017

PALABRAS CLAVE

Ecuaciones estructurales;
Estructura de covarianza;
Análisis de trayectorias

Resumen Los modelos de ecuaciones estructurales (SEM) son una herramienta estadística multivariada que permite estudiar la relación que hay entre variables latentes y observadas. Este artículo tiene el propósito de introducir, de forma sencilla y no muy teórica, a los SEM. Se describen los tipos de modelos, su representación gráfica, su identificabilidad, las técnicas de estimación de parámetros y la valoración de su ajuste. Se incluye además un ejemplo para ilustrar esta metodología estadística.

© 2017 Universidad Nacional Autónoma de México, Facultad de Medicina. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

KEYWORDS

Structural equation;
Covariance structure;
Path analysis

Introduction to structural equation models

Abstract Structural equation models (SEM) are a multivariate statistical tool that allows to study the relationship between latent and observed variables. This article has the purpose of introducing SEM in a simple and not very technical way. We describe the different types of models, their graphical representation, their identifiability, some techniques for parameter estimation and the evaluation of their goodness of fit. An example is included to illustrate this statistical methodology.

© 2017 Universidad Nacional Autónoma de México, Facultad de Medicina. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

* Autor para correspondencia. Edificio de los Consejos Académicos de Área, planta alta, Insurgentes Sur s/n, Ciudad Universitaria, Del. Coyoacán, 04510 Ciudad de México, México. Teléfono: +56220406.

Correos electrónicos: abimanzano77@gmail.com, amanzanop@unam.mx

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

<https://doi.org/10.1016/j.riem.2017.11.002>

2007-5057/© 2017 Universidad Nacional Autónoma de México, Facultad de Medicina. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Cómo citar este artículo: Manzano Patiño AP. Introducción a los modelos de ecuaciones estructurales. Inv Ed Med. 2017. <https://doi.org/10.1016/j.riem.2017.11.002>

Introducción

Los modelos de ecuaciones estructurales (SEM) como hoy se conocen tienen su origen en el año de 1918, cuando el genetista Sewall Wright esbozó por primera vez un modelo de trayectorias para describir la contribución genética entre compañeros de camada¹. Sin embargo, no fue hasta fines de los años 70 cuando otros investigadores reconocieron la importancia de estas primeras contribuciones y comenzaron a trabajar el modelo de trayectorias. Nombres como Lawley (1940), Boudon (1965), Duncan (1969), Wiley (1969), Blalock (1970), Keesling (1972), Jöreskog (1978), Sörbom (1978) y Satorra (1985) son clave para el desarrollo de esta metodología.

El estadístico sueco Jöreskog y Sörbom desarrollaron en los años 70 el primer programa estadístico, conocido como Linear Structural Relations (LISREL)², que permitió estimar y probar los modelos de ecuaciones estructurales. Por otro lado, Jöreskog extendió el análisis factorial exploratorio concebido por Lawley³ en un modelo factorial confirmatorio⁴. Otros paquetes estadísticos que se desarrollaron fueron EQS (Bentler, 1985) y AMOS (Arbuckle, 2003). En la actualidad, es posible utilizar también STATA⁵ y R⁶ para estimar estos modelos.

El SEM es considerado una herramienta estadística multivariada, también conocida como análisis de estructura de covarianzas. Estos modelos permiten probar la relación (no causalidad) que hay entre variables observadas y latentes⁷. Una variable observada es aquella que es posible medir de manera directa, como la edad o la estatura, y una latente no se puede medir directamente (la inteligencia, la motivación, la depresión o el estrés), por lo tanto, se utilizan otras variables observadas para medirlas⁸.

Cuando el modelo de ecuaciones estructurales se compone únicamente de variables observadas (path analysis)⁹, puede tener similitud con el análisis de regresión lineal clásico; sin embargo, una cualidad que lo hace atractivo sobre la regresión es que es posible estimar el efecto (o relación) indirecto y total que tiene una variable sobre otra¹⁰.

Tipo de modelos y representación gráfica

Hay 2 tipos de modelos: los que involucran solo variables observadas (path analysis) y los que mezclan variables observadas y latentes: análisis factorial confirmatorio y modelo estructural^{11,12}. Su diferencia radica en que, en el primer caso, se busca estimar la correlación entre las variables latentes, mientras que en el segundo se pretende estimar además su asociación¹³.

Para plantear las ecuaciones asociadas al modelo, es necesario que en primer lugar se represente gráficamente. Una variable observada se simboliza por medio de un cuadrado, una latente por un círculo o elipse, una asociación con una flecha unidireccional y una correlación con una flecha bidireccional. En la figura 1 se muestra un modelo estructural que contiene 3 variables latentes ξ_1 , η_2 y η_3 . La primera corresponde a una variable latente independiente (ξ_1) ya que a ella no llega ninguna flecha y, por el contrario, las otras 2 (η_2 y η_3) son dependientes ya que les llega al menos una flecha. Cada una de estas 3 variables latentes está medida a través de 3 variables observadas. Nótese que se destacan las observadas asociadas a la latente

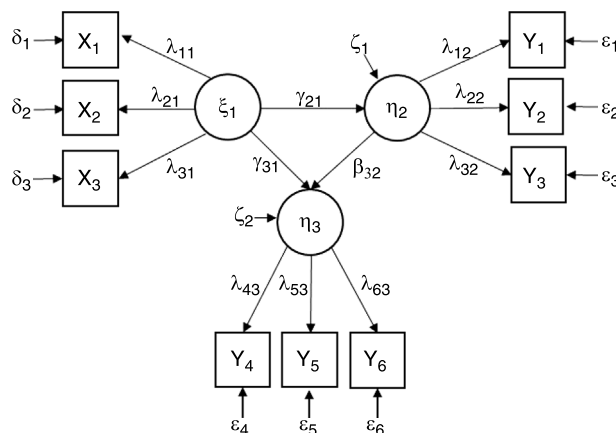


Figura 1 Ejemplo de un modelo de ecuaciones estructurales con 3 variables latentes, cada una de ellas medida a través de 3 variables observadas.

independiente como X, mientras que para las latentes dependientes con Y.

Se define el efecto directo como la relación inmediata que hay entre una variable y otra, el efecto indirecto como la relación entre 2 variables, mediada al menos por otra diferente de estas, y el efecto total como la suma del efecto directo e indirecto¹⁴. En el caso de la figura 1, los efectos directos entre latentes son las trayectorias que van de ξ_1 a η_2 (coeficiente γ_{21}), de η_2 a η_3 (coeficiente β_{32}) y de ξ_1 a η_3 (coeficiente γ_{31}). El único efecto indirecto es el que va de ξ_1 a η_3 pasando por η_2 (coeficientes γ_{21} y β_{32}) y, por lo tanto, el efecto total de ξ_1 a η_3 estaría dado por la suma de los coeficientes de las trayectorias $\xi_1 \rightarrow \eta_2 \rightarrow \eta_3$, esto es, $\gamma_{31} + (\gamma_{21} \cdot \beta_{32})$. Las letras representadas como δ , ϵ y ζ corresponden a los errores asociados a las variables observadas y a las latentes dependientes.

Parámetros del modelo

En los SEM se pueden estimar los siguientes parámetros: todos los coeficientes que conectan a variables latentes con sus respectivas variables observadas, los que conectan a latentes con latentes, los que conectan observadas con observadas, las varianzas de variables independientes y las covarianzas entre ellas, las varianzas de los errores asociados a variables dependientes y las covarianzas entre ellas. A estos parámetros se los denomina *libres*. En el caso de que el investigador tenga una hipótesis acerca del valor que debería tomar un parámetro podrá establecerlo y, por lo tanto, ya no será *libre*, sino *fijo*. Un requisito fundamental es que se tiene que fijar la escala de cada una de las variables latentes del modelo. Para hacer esto, hay 2 caminos:

1. Fijar con el valor de 1 la varianza de cada una de las variables latentes.
2. Fijar con el valor de 1 una trayectoria de cada una de las variables latentes con una de sus variables observadas.

Identificabilidad del modelo

Se dice que un modelo es identificable si es posible encontrar un valor único para cada uno de los parámetros del modelo. Un modelo no puede ser identificable si se establece como parámetro libre a uno que por definición no es parámetro estimable, por ejemplo, una correlación entre variables dependientes. Cuando el modelo tiene más parámetros *fijos* que ecuaciones, entonces al menos un parámetro se expresará en términos de otro y, por lo tanto, no tiene un valor único (solución única) o cuando encontramos valores poco plausibles como, por ejemplo, varianzas negativas. Existen reglas que permiten determinar si el modelo planteado es identificable; estas varían dependiendo del tipo de modelo. La regla más sencilla y que aplica a todos los modelos es la *regla t*. En ella se establece que el número de parámetros libres (t) tiene que ser menor o igual al número de variables observadas del modelo (p) entre 2. $t \leq \frac{p(p+1)}{2}$

Sin embargo, además de esta regla se deben utilizar otras en conjunto para asegurar la identificabilidad¹⁵. Aunque en este trabajo no se profundiza en este tema, se deja al lector el nombre de estas reglas para que pueda revisarlas con detenimiento. Para los modelos de análisis de trayectoria: regla de la B nula, regla recursiva, regla de condición de rango y orden; para el modelo confirmatorio: regla de 2 variables observadas y de 3 variables observadas, y para el modelo estructural: regla de los 2 pasos y regla MIMIC¹⁶.

Estimación del modelo

La principal hipótesis que se contrasta es que la matriz de varianzas y covarianzas poblacional (Σ) es igual a la matriz de varianzas y covarianzas asociada al modelo teórico ($\Sigma[\theta]$)¹⁷. En la práctica, es difícil que se cumpla esta igualdad; sin embargo, los métodos de estimación permiten encontrar $\hat{\theta}$ (vector de parámetros), de tal forma que Σ sea lo más cercano a $\Sigma(\hat{\theta})$. Como Σ no es conocida, se utiliza la matriz de varianzas y covarianzas muestral (S) como el estimador de Σ .

La diferencia entre estas 2 matrices $S - \Sigma(\hat{\theta})$ se conoce como residuo y por medio de estos residuos es posible cuantificar la discrepancia que hay entre lo que se observa por medio de los datos y las estimaciones derivadas del modelo.

Los métodos de estimación que se utilizan con mayor frecuencia son máxima verosimilitud (ML), mínimos cuadrados ordinarios (OLS), mínimos cuadrados generalizados (GLS) y mínimos cuadrados no ponderados o de distribución asintóticamente libre (ULS o ADF). Todos estos métodos trabajan iterativamente con el objetivo de minimizar una función de ajuste que se escribe en términos de las matrices antes descritas. Esta función de ajuste dependerá del método de estimación que se utilice.

El método de ML es el que se utiliza con mayor frecuencia y requiere que se cumpla el supuesto de normalidad de los datos, aunque se ha demostrado que bajo pequeñas desviaciones de normalidad el método sigue siendo consistente¹⁸. Los OLS y los GLS también trabajan bajo el supuesto de normalidad de los datos; sin embargo, estos métodos arrojan estimaciones más exactas aun a pesar de violar el supuesto de normalidad y, a diferencia de ML, se comportan mejor aunque el tamaño de muestra sea pequeño

($n < 200$)¹⁹. Cuando definitivamente la distribución de los datos no es normal, se puede utilizar el método de ADF²⁰. Este método es empleado particularmente cuando las variables del modelo son categóricas (se emplean correlaciones policóricas, tetracóricas y poliseriales)²¹. Una desventaja de este método es que requiere que el tamaño de muestra sea grande ($n > 250$).

Bondad de ajuste del modelo

Una vez que se estimaron los parámetros del modelo, se tiene que hacer la evaluación del ajuste. Una de las pruebas más conocidas es la prueba de χ^2 , la cual se utiliza para contrastar la hipótesis principal:

$$H_0 : S = \sum (\hat{\theta}) \text{ vs } H_1 : S \neq \sum (\hat{\theta})$$

esto es, que la matriz de varianzas y covarianzas muestral es igual a la matriz de varianzas y covarianzas descrita en términos de los parámetros del modelo. En el caso en que el ajuste del modelo sea bueno, este estadístico t se distribuye como una ji al cuadrado con $\frac{t(t+1)}{2} - p$ grados de libertad, en donde t representa el número de parámetros estimados y p el número de variables observadas. Para aceptar la hipótesis nula, el valor del estadístico tiene que ser menor que el valor en tablas de una ji al cuadrado con los grados de libertad descritos arriba y con un nivel de significación α . Dado que el valor del estadístico se escribe en términos del tamaño de la muestra ($t = (n - 1)F_{\min}$), entonces para muestras grandes, t tiende a incrementar su valor, lo que hace que con mayor frecuencia se rechace la hipótesis nula (H_0) (se incrementa el error tipo I) y, por lo tanto, puede ser más frecuente que se concluya que el modelo propuesto no es adecuado²². Lo antes mencionado hace necesario que además de utilizar esta prueba también se evalúen conjuntamente otros índices para concluir sobre el ajuste del modelo.

Otros índices de ajuste que se usan son Goodnes of Fit Index (GFI) (este índice se puede interpretar como la proporción de varianza que se explica por medio del modelo), Adjusted Goodnes of Fit Index (AGFI), Root Mean Square Error of Aproximation (RMSEA), Standardized Root Mean Square Residual (SRMR), Comparative Fit Index (CFI), Akaike Information Criterion (AIC), Non Normed Fit Index (TLI o NNFI), Incremental Fit Index (IFI o BL89) y Expected Cross Validation Index (ECVI). La mayoría de los cuales toman valores entre 0 y 1, excepto RMSEA y SRMR. En el caso de RMSEA y SRMR se puede determinar que el ajuste es bueno si se observan valores iguales o inferiores a 0.05²³. Para el resto de los índices, lo deseable es obtener valores cercanos a 1 o al menos superiores a 0.90²⁴. Cabe mencionar que CFI, AIC, TLI, BL89 y ECVI también son conocidos como *índices de incremento*, ya que comparan el modelo propuesto con el modelo de independencia, esto es, el modelo en el que se asume que no existe asociación alguna entre las variables. En el caso de AIC y ECVI, también se comparan con el modelo saturado y si se plantean varias versiones del modelo se pueden comparar entre sí. Otra medida que se puede utilizar para evaluar el modelo es el tamaño de los residuos estandarizados, ya que por medio de ellos se determina la diferencia que hay entre lo observado por medio de los datos y lo que se obtiene de la estimación del modelo. Lo deseable

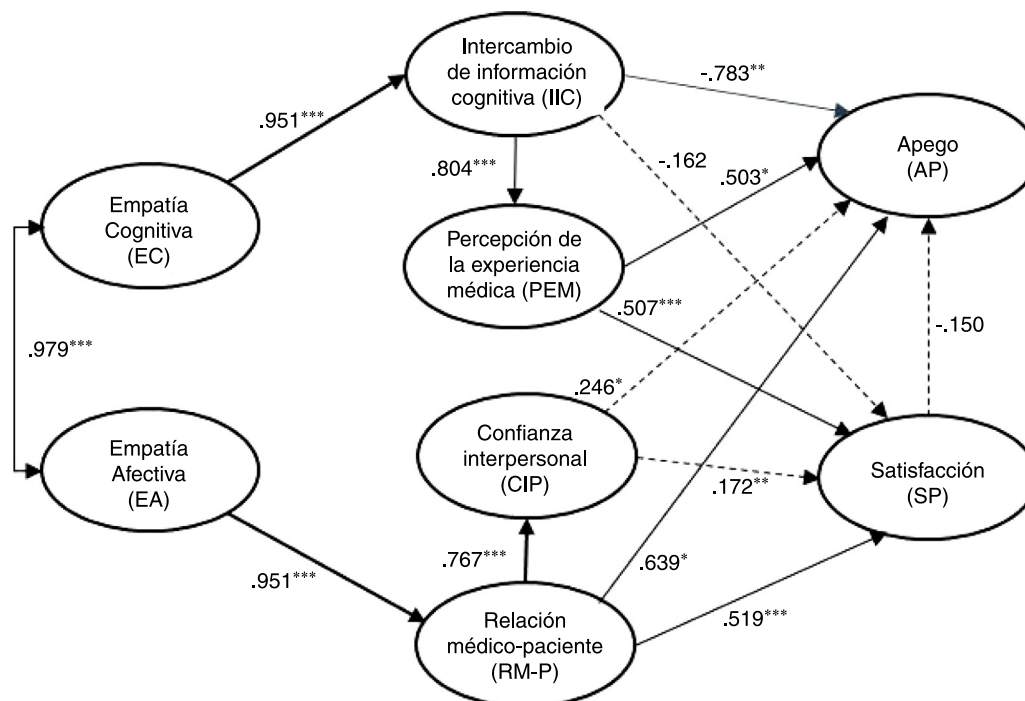


Figura 2 Modelo de empatía. * $p < 0.05$. ** $p < 0.01$. *** $p < 0.001$.

Tabla 1 Efecto total que tienen las variables predictoras del modelo en la satisfacción y apego del paciente

Variable latente predictorora	Apego del paciente	Satisfacción del paciente
Relación médico-paciente	0.730	0.651
Empatía afectiva	0.695	0.620
Percepción de la experiencia médica	0.427	0.507
Intercambio de información cognitiva	-0.415	0.244
Empatía cognitiva	-0.394	0.232
Confianza interpersonal	0.221	0.172

es obtener residuos muy cercanos a cero, aunque un rango aceptable es entre -2 y 2.

Cuando el ajuste del modelo no resulta aceptable, puede ser viable replantear el modelo (con sustento teórico), verificar su identificabilidad, estimarlo y nuevamente evaluar el ajuste.

Ejemplo de un modelo de ecuaciones estructurales

Atendiendo a que la población a la que va dirigido este artículo metodológico es eminentemente del área médica, se buscó un artículo que pudiera ejemplificar el uso de las ecuaciones estructurales en dicha área. Este apartado no pretende tocar a profundidad los conceptos que se abordan en este modelo, más bien tiene como fin mostrar como a través de varias hipótesis se puede plantear un modelo y analizarlo con esta metodología.

Kim et al.²⁵ querían explorar el efecto que tiene la empatía médica con la satisfacción y el apego que muestran los

pacientes. El estudio se llevó a cabo con 550 pacientes de un hospital universitario en Corea, a los cuales se les aplicó un cuestionario. Midieron 2 tipos de empatía: *afectiva* (capacidad que tiene el médico para responder con un sentimiento adecuado ante el paciente) y *cognitiva* (capacidad que tiene el médico para ponerse en el lugar del paciente). Entre las hipótesis que plantearon, mencionan que las 2 empatías tienen un efecto positivo en la satisfacción y el apego; sin embargo, este efecto no es directo, sino que está mediado por otros factores. En el caso de la empatía cognitiva (EC), el efecto que tiene sobre la satisfacción del paciente (SP) está mediada por el intercambio de información cognitiva (IIC) (capacidad que tiene el médico de informar al paciente con precisión y claridad todo lo relacionado con el padecimiento) y la percepción de la experiencia médica (PEM), mientras que la empatía afectiva (EA) lo hace por medio de la confianza interpersonal (CIP) y la relación médico-paciente (RM-P). Otras hipótesis que establecieron son: entre más empático sea el médico mayor serán la satisfacción (SP) y el apego del paciente (AP). Indican, además, que el IIC y la PEM tienen un efecto más fuerte en el fac-

tor de apego que en el de satisfacción, mientras que la CIP y la RM-P tienen un efecto mayor sobre la satisfacción que con el apego²⁶⁻²⁸. La figura 2 muestra el modelo hipotético.

Las pruebas que hicieron para evaluar la confiabilidad de las variables latentes no se abordarán en este trabajo, por lo que sugerimos que para mayor detalle se consulte el artículo. Para estimar y evaluar el modelo se utilizó el paquete EQS 5.7. Se ajustaron 2 modelos: un confirmatorio y uno de ecuaciones estructurales, aunque solo discutiremos el segundo (fig. 2). Cabe mencionar que ambos modelos tuvieron un ajuste muy bueno. Para el segundo modelo se reportó una $\chi^2(467) = 1,066.992$ con $p < 0.001$, $CFI = 0.931$ y $RMSEA = 0.049$. Considerando el valor de estos 3 índices se puede concluir que el modelo tiene buen ajuste, aunque hubiese sido importante que se mostraran otros índices de incremento. En la figura 2, los autores destacan con una flecha sólida aquellos coeficientes que resultaron muy significativos ($p < 0.001$) y con flechas punteadas los que fueron poco o nada significativos. El modelo mostró que la correlación entre la EC cognitiva y afectiva es positiva y muy significativa ($p < 0.001$). Se confirmó que el médico que tiene mayor EC tiene mayor IIC (0.951 , $p < 0.001$) y que a mayor IIC mayor PEM (0.804 , $p < 0.001$). A mayor EA, es la RM-P (0.951 , $p < 0.001$), y a mayor RM-P se incrementa la CIP (0.767 , $p < 0.001$). El efecto directo que tiene la IIC en la SP y el AP fue negativo en ambos casos, pero significativo solo con el AP, conclusión que es contraria a lo que se habían planteado. En el caso de PEM, tiene un efecto similar en SP (0.507 , $p < 0.001$) y en AP (0.503 , $p < 0.05$). Tanto RM-P como CIP tienen un efecto directo positivo en SP y AP, aunque la magnitud de los coeficientes es mayor en RM-P con SP y AP (0.519 y 0.639) que en CIP con SP y AP (0.172 y 0.246).

Presentan además los valores del efecto total que tiene cada una de las variables predictoras del modelo en la satisfacción (SP) y el AP (tabla 1), aunque no mencionan si estos efectos fueron estadísticamente significativos, lo cual resulta importante. La RM-P y la EA mostraron el mayor efecto total sobre la SP y el AP. IIC y EC tienen el efecto total más bajo y negativo sobre el AP. La EC y la CIP los más bajos sobre SP.

A modo de ejemplificar brevemente cómo se obtiene el efecto total, haremos el cálculo entre la variable RM-P y el AP. Mencionaremos las trayectorias que se utilizaron para el cálculo, para lo cual el lector puede usar la figura 2 como apoyo.

RM-P + SP + AP + RM-P + CIP + AP + RM-P + CIP + SP + AP + RM-P + AP

Esto es,

$$(0.519) + (-0.150) + (0.767) + (0.246) + (0.767)(0.172) + (-0.150) + 0.639 = 0.730.$$

Algunas conclusiones: los factores emocionales EA y RM-P asociados al médico desempeñaron el papel más importante para aumentar la satisfacción y el apego de los pacientes del estudio, seguido de PEM, que inesperadamente también fue un buen predictor. La relación negativa entre IIC y AP no era esperada, indicando que posiblemente existen otros factores intermedios que no fueron contemplados, como, por ejemplo, problemas en el manejo de la enfermedad, entre otras explicaciones que mencionan.

Ventajas y desventajas de utilizar los Modelos de Ecuaciones Estructurales

Entre las ventajas que supone el uso de esta metodología se encuentra probar simultáneamente la relación directa, la relación indirecta y total entre las variables, la inclusión de más de una variable dependiente y sus respectivos errores de medición, la correlación entre variables y también entre los errores de medición²⁹. También es posible usar los SEM en diseños longitudinales, como series de tiempo³⁰ y modelos de crecimiento¹⁶.

Entre las limitaciones que tiene el SEM es que requiere de muestras grandes ($n > 200$), lo que podría ser difícil de obtener. Algunos autores indican que por cada parámetro libre o por cada variable observada, debe haber al menos 10 casos¹⁹. Plantear un modelo supone un reto importante, ya que lo ideal es que el investigador cuente con un amplio conocimiento teórico sobre el fenómeno que quiere estudiar, de lo contrario, se puede tener un modelo con buen ajuste pero sin sustento teórico. Esta metodología no está excluida de fallar si se utilizan variables latentes con baja confiabilidad. Finalmente, emplear esta metodología puede implicar un reto considerable si no se tiene cierto bagaje estadístico.

Financiación

Ningún tipo de financiamiento.

Conflicto de intereses

Declaro no tener ningún conflicto de interés.

Referencias

- Westland JC. Structural equation models: From paths to networks. Springer. 2015:175.
- Jöreskog K, Sörbom D. LISREL 9.3. Scientific Software International. 2008.
- Lawley DN. The estimation of factor loadings by the method of maximum likelihood. Proceedings of the Royal Society Edinburgh. 1940;60:64-82.
- Jöreskog KG. A general approach to confirmatory maximum likelihood factor analysis. Psychometrika. 1969;34:183-202.
- Stata Corp. Stata: Release 13. Statistical Software College Station; 2013.
- Rosseel Y. Lavaan: An R package for structural equation modeling. Journal of Statistical Software. 2012;48:1-36.
- Bollen KA. Structural equations with latent variables. New York: Wiley; 1989.
- Bartholomew DJ, Steele F, Galbraith J, Moustaki I. Analysis of multivariate social science data. 2nd ed. Chapman & Hall; 2008.
- Stage FK, Cartyer HC, Nora A. Path analysis: An introduction and analysis of a decade of research. Journal of Education Research. 2004;98:5-12.
- Keith TZ. Multiple regression and beyond: An introduction to multiple regression and structural equation modeling. 2nd ed. New York: Taylor & Francis; 2015.
- Mulaik SA. Foundations of factor analysis. 2nd ed. Boca Raton: Chapman & Hall/CRC; 2009.
- Loehlin JC, Beaujean AA. Latent variable models. An introduction to factor, path and structural equation analysis. 5th ed. New York: Taylor & Francis; 2017.

13. Nachtigall C, Kroehne U, Funke F, Steyer R. (Why) should we use SEM? Pros and cons of structural equation modeling. *Methods of Psychological Research Online*. 2003;8:1–22.
14. Bollen KA. Total direct, and indirect effects in structural equation models. *Sociological Methodology*. 1987;17:37–69.
15. Bollen KA, Davis WR. Two rules of identification for structural equation models. *Structural Equation Modeling: A Multidisciplinary Journal*. 2009;16:523–36.
16. Kline RB. *Principles and practice of structural equation modeling*. 4th ed. New York: The Guildford Press; 2015.
17. Bollen KA, Long JS. *Testing structural equation models*. California: SAGE; 1993.
18. Muthén B. En: Bollen KA, Long JS, editores. *Goodness of fit with categorical and other nonnormal variables. Testing structural equation models*. California: SAGE; 1993. p. 205-234.
19. Bentler PM, Yuan K. Structural equation modeling with small samples: Test statistics. *Multivariate Behavioral Research*. 1999;34:181–97.
20. Browne MW. Asymptotically distribution-free methods for the analysis of covariance structures. *British Journal of Mathematical and Statistical Psychology*. 1984;37:62–83.
21. Muthén B. Latent variable structural equation modeling with categorical data. *Journal of Econometrics*. 1983;22:43–65.
22. Schumacker RE, Lomax RG. *A begginer's guide to structural equation modeling*. 2nd ed. Mahwah, NJ: Lawrence Erlbaum Associates; 2004.
23. Steiger JH. Point estimation, hypothesis testing and inter-val estimation approach. *Multivariate Behavioral Research*. 1990;25:173–80.
24. Hu L, Bentler PM. Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternati-ves. *Structural Equation Modeling: A Multidisciplinary Journal*. 1999;6:1–55.
25. Kim SS, Kaplowitz S, Johnston MV. The effects of physician empathy and patient satisfaction and compliance. *Evaluation & Health Professions*. 2004;27:237---51.
26. Mehrabian A, Epstein N. A measure of emotional empathy. *Journal of Personality*. 1972;40:525–43.
27. Olson JK. Relationships between nurse-expressed empathy, patient-perceived empathy and patient distress. *Image: The Journal of Nursing Scholarship*. 1995;27:317---22.
28. Squier R. A model of empathic understanding and adherence to treatment regimens in practitioner-patient relationships. *Social Science & Medicine*. 1990;30:325---39.
29. Hermida R. The problem of allowing correlated errors in structural equation modeling: concerns and considerations. *Computational Methods in Social Sciences*. 2015;3:1---17.
30. Farrell AD. Structural equation modeling with longitudinal data: Strategies for examining group differences and recipro-cal relationships. *Journal of Consulting and Clinical Psychology*. 1994;62:477---87.