

Castañeda-Figueiras, Sandra; Austria-Corrales, Fernando

Generando evidencias en investigación de educación médica: modelamiento estructural de variables

Investigación en Educación Médica, vol. 3, núm. 11, 2014, pp. 161-168

Universidad Nacional Autónoma de México

Distrito Federal, México

Disponible en: <http://www.redalyc.org/articulo.oa?id=349733966007>



Investigación en Educación Médica,

ISSN (Versión impresa): 2007-865X

revistainvestedu@gmail.com

Universidad Nacional Autónoma de México

México



Investigación en
Educación Médica

<http://riem.facmed.unam.mx>



METODOLOGÍA DE INVESTIGACIÓN EN EDUCACIÓN MÉDICA

Generando evidencias en investigación de educación médica: modelamiento estructural de variables

Sandra Castañeda-Figueiras, Fernando Austria-Corrales

Laboratorio de Evaluación y Fomento del Desarrollo Cognitivo y el Aprendizaje Complejo, Posgrado de la Facultad de Psicología, Universidad Nacional Autónoma de México, México D.F., México

Recepción 24 de febrero de 2014; aceptación 5 de marzo de 2014

PALABRAS CLAVE

Generación de evidencias; toma de decisiones; educación médica; modelamiento de ecuaciones estructurales; México.

Resumen

El trabajo se inserta en el campo de la investigación en educación médica en lo general, y en lo particular, en la generación de evidencias usando modelamiento estructural de variables. Se discute la necesidad de que el investigador en educación médica sea sensible a la complejidad de los resultados de aprendizaje, derivados de la formación médica cuando elija el modelo de análisis estadístico que va a usar, de manera tal que se supere la insuficiencia de los modelos univariados para analizar fenómenos complejos. Así, es factible optimizar la generación de evidencias que respondan a la complejidad de lo estudiado y, optimicen la toma de decisiones en educación médica. El trabajo revisa modelos multivariados brevemente y ofrece ejemplos concretos de técnicas multivariadas aplicadas a la investigación en salud.

KEYWORDS

Evidence generation; decision making; medical education; structural equation modeling; Mexico.

Generating evidence in medical education research: Structural equation modeling

Abstract

The work is inserted into the field of research in medical education in general, and in particular, in the generation of evidence using structural modeling variables. Discussed the need that the researcher in medical education is sensitive to the complexity of the learning outcomes derived from medical training when choose the model of statistical analysis to be used, in such a way that exceeded the inadequacy of univariate models to analyze complex phenomena. Thus, it is possible to optimize the generation of evidence that respond to the complexity of the studied and streamline decision-making in medical education. The work briefly reviews multivariate models and offers concrete examples of multivariate techniques applied to research in health.

Correspondencia: Dra. Sandra Castañeda Figueiras. Av. Universidad N° 3004, edificio "D", último piso, cubículo 6, Colonia Oxtoculco, C.P. 04510, México D.F., México. Teléfono: (55) 5622 2284. Correo electrónico: sandra@unam.mx.

Introducción

La educación médica constituye un espacio en el que convergen disciplinas diversas, marcos conceptuales y metodológicos variados, tanto como prácticas educativas tradicionales y novedosas. En él, las revistas especializadas compiten por la atención de sus lectores y por influir, de alguna forma, en la toma de decisiones sobre el qué, el para qué y el cómo enseñar en las escuelas y Facultades de Medicina. Lamentablemente, no es poco frecuente observar que las evidencias en las que se fundamentan las recomendaciones por tal o cuál estrategia, táctica o contexto instruccional, son poco útiles para explicar, entender o derivar el fomento del fenómeno en estudio, dado que es insuficiente para capturar su complejidad inherente. Más bien, adoptan una aproximación simplista en la que se sobredimensiona lo elemental y parcializado sobre una aproximación más integral al estudio del aprendizaje complejo, característico de la formación universitaria.¹

Es bien conocido que el crecimiento acelerado del conocimiento en Medicina, hace imposible que los médicos en formación puedan aprender todo el conocimiento y todas las habilidades que necesitan durante su formación académica y a todo lo largo del ejercicio profesional como médicos.² De aquí que los médicos en formación además de aprender conocimientos y habilidades para el aquí y el ahora, requieran identificar sus necesidades personales de aprendizaje continuo y desarrollar los recursos y materiales para poder satisfacerlas.

En este contexto, el propósito de la educación médica es desarrollar expertos en Medicina que se caractericen por tener un conocimiento profundo de la materia y que cuentan con habilidades cognitivas y metacognitivas que les permiten regular su comportamiento ante situaciones complejas. Los expertos son capaces de monitorear y regular cuidadosa y sistemáticamente sus experiencias y, además, actuar de manera rápida en la solución de problemas o actuar intuitivamente, cuando es necesario.³

Más bien, lo que en la educación médica se necesita es fomentar un estudiante competente en adquirir, de manera continua, nuevos conocimientos a partir de la experiencia consigo mismo y con otros en un área de competencia y no, simplemente, formar un estudiante competente en esa área, en un punto definido en el tiempo. Así, los resultados asociados con un área de competencia no sólo deben centrarse en el rendimiento actual del estudiante en esa área, se requiere, además, su capacidad para evaluar, supervisar y mejorar el desempeño, continuamente. De esta manera, capacidades metacognitivas y autorregulatorias pueden ayudar a mejorar el desempeño y garantizar aprendizajes para toda la vida, en vez de aprendizajes para el aquí y el ahora.

Pero la realidad universitaria en el contexto nacional, muestra una alarmante proporción de estudiantes de educación superior que no son exitosos y en donde el nivel de dominio en heurísticas cognitivas y autorregulatorias, tanto como la ingenuidad de sus sistemas de creencias, no fomentan la producción de experiencias que les permitan influir sobre el curso de sus vidas. Más bien (y en el mejor de los casos), desarrollan conocimiento inerte y competencias para “el aquí y el ahora”. La naturaleza efímera de los resultados de este tipo de aprendizaje explica la

falla del paradigma tradicional al preparar competencias personales y profesionales “para toda la vida” en los futuros profesionales.

Se sabe que en diversas disciplinas profesionales (Medicina, Ingeniería, Psicología, etc.), líderes del currículo han enfatizado la promoción de aprendizajes “para toda la vida”, pero sus demandas no han tenido el éxito deseado, no hay cambios sustantivos en la realidad de la oferta en educación superior. La literatura especializada muestra que se continúa centrando el currículo, la enseñanza y la evaluación en conocimientos del “aquí y ahora”. De aquí que se reconozca la necesidad de fomentar capacidades permanentes (a todo lo largo de la vida), que construyan, monitoreen y regulen experiencias promotoras de mejora continua, como también se reconoce la necesidad de hacer investigación sobre la complejidad en este tipo de aprendizaje.

Sin lugar a dudas, esto plantea desafíos a la investigación y al diseño instruccional, de manera tal que sus productos generen condiciones para el crecimiento general deseado, en vías de aliviar las grandes diferencias entre países. Así, el nuevo paradigma educativo requiere del aprendizaje basado en el desarrollo de desempeños críticos, con alto valor formativo a partir de tareas de la vida real. Es decir, competencias instrumentales que además de integrar conocimientos, habilidades y actitudes en competencias capaces de resolver problemas y facilitar transferir lo aprendido a tareas nuevas, potencien la agentividad de los estudiantes.

Así, entender la estructura del Sentido de Agencia Académica ante situaciones académicas exigentes, explicaría el tipo de características a investigar para poder evolucionar del estudio de meras conductas simples a la investigación del nivel en el que influyen las acciones intencionales sobre el aprendizaje académico. También permitiría identificar cuáles son las condiciones normativas del éxito de tales acciones. Implica conocer y entender el interjuego entre componentes de acción que el agente debe poseer para estar dotado de agencia y donde el estudiante sea capaz de ejercer influencia personal sobre su ambiente y desempeñar un papel activo en la transformación requerida, incluyendo la suya propia. En otras palabras, comprender la estructura de lo característico de la acción autónoma humana integral, más allá de indagar formas aisladas (independientes unas de otras), utilizadas durante el aprendizaje académico.

Pero, pocos avances se identifican en la generación de evidencias que permitan reflexionar críticamente sobre los componentes que intervienen en el mejoramiento general de la educación que ofertamos en las universidades y hospitales. Generar tales evidencias no es cosa fácil, sobre todo si consideramos en primera instancia que los fenómenos educativos son de naturaleza multifactorial y multicausada. Es decir, que múltiples variables intervienen en su fomento y evaluación, y por tanto en su investigación. Un problema adicional es que la mayor parte de las variables involucradas en dichos fenómenos son latentes, es decir, no son directamente observables ni medibles, sin embargo es posible estimar su media y su varianza a través de indicadores.⁴

Debido a estas circunstancias y dificultades, en el estudio científico de los fenómenos educativos, principalmente

del aprendizaje complejo, los métodos estadísticos univariados y multivariados tradicionales, no son suficientes para explicar los efectos conjuntos que ejercen variables cognitivas y autorregulatorias sobre el aprendizaje. Por ejemplo, utilizar métodos de regresión multivariada presenta diversos inconvenientes, en tanto que requieren asumir distintos supuestos para realizar inferencias válidas sobre los componentes que están involucrados, a saber: a) las variables dependientes deben distribuirse normalmente, b) las variables independientes no deben asociarse (no deben presentar problemas de colinealidad) y, c) las métricas de las variables involucradas en el modelo deben de ser continuas. En este sentido, y como se ha revisado anteriormente, las variables involucradas en el fomento del aprendizaje generalmente se encuentran asociadas, lo que violaría uno de los supuestos básicos para utilizar análisis de regresión múltiple; además, estas variables no siempre se distribuyen normalmente de acuerdo con la población que se esté estudiando.

Otro ejemplo puede observarse al utilizar análisis de la varianza de uno, dos o tres factores, utilizando el modelamiento general multivariante, que aunque tiene opciones robustas para soportar muestras que no asumen la normalidad en sus variables dependientes, se ven amenazadas en tanto que no son capaces de analizar variables latentes, mismas que caracterizan el estudio de los fenómenos educativos.

Un ejemplo más se relaciona con el uso de correlaciones, en donde el problema radica en establecer la naturaleza y la dirección de las variables que se asocian, es complicado establecer si los efectos de una variable producen resultados sobre otra o viceversa, digamos, un problema para un investigador sería determinar si un alto prestigio en una instancia académica genera estudiantes de alto rendimiento o si los estudiantes de alto rendimiento son los que generan el prestigio de la institución.⁵

En este contexto y a través de años de investigación se desarrollaron un conjunto de técnicas estadísticas denominadas modelamiento de ecuaciones estructurales (*Structural Equation Modeling*), con el propósito de suministrar herramientas adecuadas para modelar estadísticamente fenómenos complejos multifactoriales-multicausados; dicho conjunto de análisis consiste en la combinación de diversas técnicas estadísticas, tales como: 1) el análisis de estructura de covarianza (ANCOVA), 2) la regresión multivariada (RM) y 3) el análisis factorial confirmatorio (AFC), entre otras.⁶⁻⁹

Los modelos de ecuaciones estructurales consisten en una familia de técnicas estadísticas confirmatorias, entre las que se pueden mencionar las siguientes:

1. *Análisis de senderos*, desarrollado por Sewall Wrigth en los años 60, consiste en modelar efectos directos e indirectos de variables observables o manifiestas, reduciendo así los problemas de multicolinealidad al combinar la regresión multivariada con el análisis de la estructura de covarianza. Esto permite identificar la dirección de los efectos, así como cuantificar la magnitud de los mismos; además es posible modelar variables categóricas y continuas dentro del mismo modelo.⁹
2. *Análisis factorial confirmatorio*, desarrollado inicialmente por Jöreskog a finales de los años 60, se

caracteriza por la posibilidad de modelar variables latentes con base en un modelo teórico desarrollado apriorísticamente. Esta técnica se diferencia del análisis factorial exploratorio desarrollado por Spearman en 1904, en tanto que su objetivo principal no es reducir dimensiones, sino confirmar hipótesis basadas en modelos teóricos de naturaleza explicativa.¹⁰

3. *Modelamiento de ecuaciones estructurales de covarianzas*, también desarrollado en sus inicios por Jöreskog a finales de los años 70. Este tipo de análisis permite identificar y cuantificar efectos entre variables latentes, no sólo en términos de correlaciones, sino que también permite modelar regresiones entre variables latentes, lo que prácticamente es imposible con alguna otra técnica estadística tradicional.¹¹
4. *Modelamiento de ecuaciones estructurales de covarianzas y medias*, donde McGaw y Jöreskog fueron pioneros a finales de los años 70. Este análisis es similar al anterior, sin embargo tiene la ventaja de que posibilita la estimación de medias de las variables latentes incluidas en el modelo.¹²

La muy breve revisión de modelos, presentada aquí, no intenta ser exhaustiva ni intensiva. Recomendamos al interesado en profundizar teórica y técnicamente en el tema, así como consultar las referencias incluidas al final de este artículo. Más bien, nuestro interés es ejemplificar algunas aplicaciones de estos tipos de análisis en lo que respecta al campo de la educación en las ciencias de la salud.

Aplicaciones del análisis de senderos

El uso de análisis de senderos puede ejemplificarse con un estudio basado en el modelo de Castañeda,¹³ en el que se modelaron efectos del uso de heurísticos cognitivos y autorregulatorios sobre el desempeño académico de estudiantes en terapia respiratoria del Instituto Nacional de Enfermedades Respiratorias, realizado por Austria.¹⁴ Se hipotetizaron predictores del desempeño académico a corto y mediano plazo, asociando variables cognitivas y autorregulatorias a los promedios obtenidos por los estudiantes en tres cuatrimestres sucesivos.

Dado que las variables medidas eran todas manifiestas, se procedió a utilizar la técnica de análisis de senderos. El ajuste estadístico y práctico fue muy bueno ($X^2=2.70$; $p=0.91$; CFI=1.000; RMSEA=0.001), lo que indicó que no existían diferencias significativas entre el modelo hipotetizado en un principio y los datos recolectados empíricamente. Los resultados mostraron la red de asociaciones entre variables cognitivas, autorregulatorias y los promedios escolares en los tres momentos: las estrategias cognitivas y autorregulatorias impactan los promedios escolares diferencialmente: el uso de estrategias de adquisición selectiva ($B=0.21$; $p<0.01$) y las creencias sobre autoeficacia ($B=0.38$; $p<0.01$) resultaron predictores del desempeño académico en el primer cuatrimestre, mientras que éstos dejan de tener efectos en los cuatrimestres posteriores. En el segundo cuatrimestre son las estrategias de recuperación ante exámenes ($B=0.48$; $p<0.01$), las de adquisición generativa ($B=0.22$; $p<0.01$), las de aprobación externa ($B=0.35$; $p<0.01$) y la regulación de

materiales ($\beta=0.41$; $p<0.01$) las que predicen el desempeño académico, mientras que en el tercer cuatrimestre lo único que predice son los conocimientos previos a cada semestre.

En primera instancia es posible identificar efectos directos e indirectos de las variables independientes sobre las dependientes: por ejemplo, veamos los predictores del promedio del primer semestre, estos son las estrategias de adquisición selectiva ($\beta=0.21$; $p<0.01$) y la autoeficacia ($\beta=0.38$; $p<0.01$), a estos coeficientes les llamaremos *efectos directos*, en tanto que se vinculan de manera directa a través de un sendero y no están mediados por otras variables del modelo. Sin embargo, obsérvese cómo las estrategias de adquisición generativas correlacionan con las de adquisición selectiva ($r=0.25$; $p<0.01$) y posteriormente las selectivas predicen el promedio del primer semestre, en este caso hablamos de un efecto indirecto de las estrategias de adquisición generativa, mediado por las selectivas, que finalmente predecirá el promedio escolar del primer cuatrimestre.

En este sentido, el procedimiento para estimar los efectos indirectos consiste en realizar el producto de los coeficientes de los senderos, en este caso se multiplica el 0.25 por 0.21, el resultado es 0.05, este es el valor del efecto indirecto de las estrategias de adquisición generativas sobre el promedio del primer cuatrimestre.

Además de lo anterior, también es posible estimar el efecto total de una variable independiente sobre otra dependiente, esto se hace a través de sumar el efecto directo y el indirecto.

En la **Figura 1** se puede apreciar el modelo resultante, donde se representan con rectángulos las variables manifiestas del modelo, en contorno punteado las que son dependientes y con línea sólida las independientes; las flechas unidireccionales se interpretan como coeficientes de regresión multivariada y las flechas bidireccionales como coeficientes de correlación.

Como puede observarse en la **Figura 1**, a diferencia de los alcances que se pueden obtener realizando un análisis de regresión múltiple, con el análisis de senderos es posible observar los efectos directos e indirectos ocasionados por las variables independientes sobre las dependientes, por lo que es posible establecer al menos tres ventajas claras de esta técnica:

1. Se superan los problemas de colinealidad, de tal forma que es posible estimar las covariaciones entre las variables independientes y reducir la probabilidad de encontrar correlaciones espurias.
2. Estimar los efectos totales de cada uno de los predictores, entendido como la sumatoria del efecto directo más el efecto indirecto (la sumatoria de

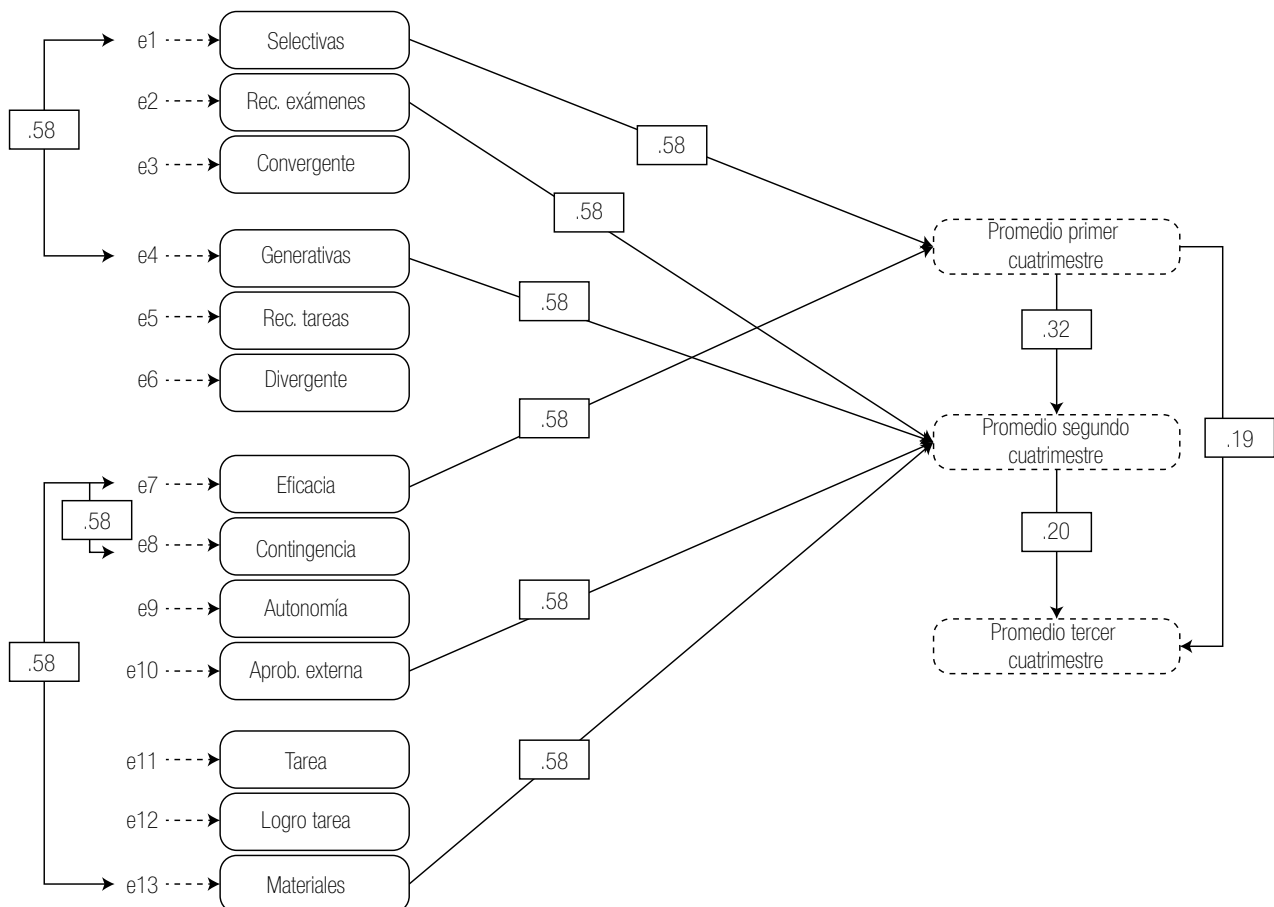


Figura 1. Ji cuadrada=2.70; $p=0.91$; CFI=1.000; RMSEA=0.001.

los productos de los efectos indirectos de las posibles trayectorias que vinculen la variable independiente y la dependiente). De esta forma es posible estimar el total de la varianza explicada por cada uno de los predictores y no en general como ocurre en la regresión múltiple.

3. Estimar el ajuste del modelo teórico con respecto a los datos empíricos, a través de tres tipos de indicadores: estadísticos, de ajuste incremental y análisis de los residuos estandarizados, en vías de verificar las hipótesis del estudio.

En síntesis, utilizar la técnica de análisis de senderos permite a los investigadores en educación médica, cuantificar los efectos por separado y en conjunto de todas las variables incluidas en el modelo, por lo que es posible no sólo predecir los efectos de un conjunto de variables sobre otras, sino también explicar en qué medida y magnitud colabora cada una de las variables de interés.

Aplicaciones del análisis factorial confirmatorio (AFC)

Para ejemplificar el uso del AFC, incluimos un estudio de validación de constructo de un banco de ítems del Inventario de Estrategias de Estudio y Autorregulación (IEEA),¹³ ajustado a estudiantes de nuevo ingreso a la Facultad de Medicina de la Universidad Nacional Autónoma de México (UNAM). Se indagaron autovaloraciones sobre la manera personal de usar estrategias cognitivas de estudio (tanto superficiales, como profundas) y de estrategias autorregulatorias (tanto de persona, como de tarea y materiales). El estudio se realizó con 1 200 estudiantes de las generaciones 2012-2013. Los datos se utilizaron para validar cuatro variables latentes que conforman el modelo teórico asumido en este banco y que son: 1) estrategias cognitivas superficiales, 2)

estrategias cognitivas profundas, 3) estrategias de autorregulación persona y, 4) estrategias de autorregulación de tarea y materiales. El modelo teórico puede apreciarse en la Figura 2.

En el modelo se aprecian las escalas del banco de ítems representadas como rectángulos con el perímetro punteado, por su carácter de variables dependientes en el modelo. Las elipses con línea sólida, por ser independientes, representan variables latentes del modelo, es decir, las que se pretenden validar a través del AFC.

De esta forma en la Figura 2, es posible observar que ciertas escalas se agrupan teóricamente a determinadas variables latentes y su vez se restringe su asociación a otras variables. Por ejemplo, la variable latente o factor de estrategias superficiales, teóricamente debería estar explicada por las estrategias de adquisición selectiva, recuperación ante exámenes y procesamiento convergente, y no por otras variables manifiestas dentro del modelo. Asimismo, en este tipo de técnica, es posible que existan correlaciones entre las variables latentes, en el ejemplo puede observarse que teóricamente las cuatro variables latentes se encuentran asociadas entre sí.

Toda vez que se contó con un modelo teórico, fue posible realizar los análisis estadísticos pertinentes. Los resultados pueden apreciarse en la Figura 3.

Como era de esperarse ante muestras grandes ($n=1200$), la *ji cuadrada* tiende a ser significativa, por lo que no puede tomarse con seriedad el ajuste estadístico, sin embargo, en estos casos es más pertinente considerar los índices de ajuste incremental y aquellos orientados a analizar los residuos estandarizados. Los índices mostraron que no hay diferencia significativa entre el modelo teórico y el modelo empírico ($CFI=0.950$; $RMSEA=0.060$; $IC=0.000-0.070$), por lo que es factible confiar en los resultados obtenidos en el modelo.¹⁵

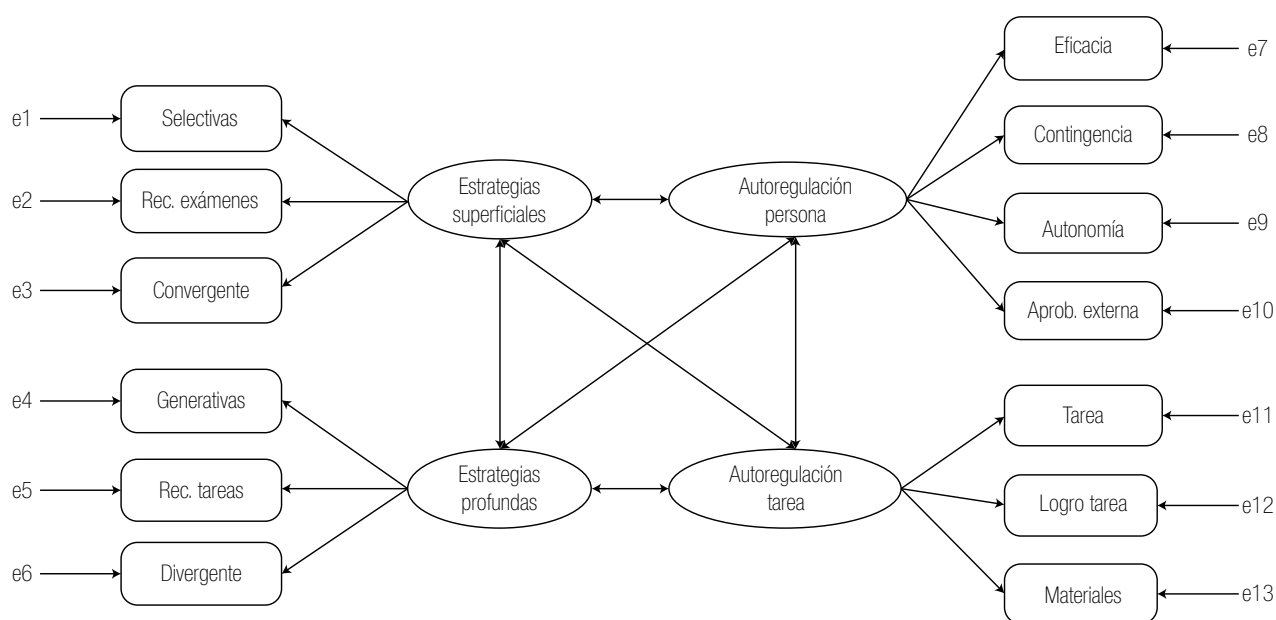


Figura 2. Modelo teórico del Inventario de Estrategias de Estudio y Autorregulación (IEEA).

En la Figura 3 es posible observar que prácticamente el modelo ajustó sin necesidad de agregar ningún parámetro extra, es decir, ninguna correlación entre variables dependientes o independientes, por lo que es factible pensar que la teorización que subyace al instrumento fue pensada y elaborada de manera precisa y bien fundamentada.

Asimismo, es posible apreciar que los pesos factoriales, aquí representados como las flechas unidireccionales que van del factor a las escalas, tienen valores adecuados, mayores que 0.30, lo que sugiere que el instrumento posee validez convergente de constructo.¹⁶

En este contexto, es posible establecer al menos dos ventajas prácticas relevantes del AFC vs. el análisis factorial exploratorio (AFE), comúnmente utilizado en problemas de investigación de validez de constructo de instrumentos:

- I. El AFC es una técnica de naturaleza confirmatoria, como su nombre lo indica, de tal forma que requiere de un modelo teórico, elaborado previamente, que permita hipotetizar la configuración de una matriz de estructura de covarianza, en contraste el AFE es un estudio de naturaleza exploratoria, por lo que no asume, inicialmente, ningún tipo de restricción. Bajo estas condiciones el AFE estará limitado para realizar comprobaciones acerca de la teoría y se corre el riesgo de que se generen asociaciones entre factores y variables manifiestas de naturaleza totalmente estadística, sin sustento teórico. Es por esta razón que cuando se analizan variables utilizando el AFE, los resultados puedan ubicar una variable manifiesta en dos, o en tres o en más factores, lo que representaría una amenaza de validez de constructo.¹⁶
- II. La otra ventaja que tiene el AFC sobre el AFE es que no requiere un método de rotación. Esto se

debe a que el proceso de estimación del AFC consiste en comparar las soluciones de dos matrices de estructura de covarianza, una hipotética y otra empírica, con el objetivo de que no sean diferentes estadísticamente; en contraste, el AFE realiza primero una extracción de los factores a través de identificar las comunales estadísticas, posteriormente rota las variables (ya sea de manera ortogonal u oblicua) con el objetivo de encontrar el mejor ajuste estadístico, sin considerar la teoría que subyace. Estas variaciones en el procedimiento, pueden ocasionar en el caso del AFE que las asociaciones que se encuentren sean puramente estadísticas o en el peor de los casos, que se asocien errores sistemáticos de medición.¹⁷

En síntesis, el AFC es una técnica factible de ser utilizada cuando se tiene el objetivo de validar la estructura factorial de modelos de medición en vías de construir e integrar instrumentos, herramienta interesante y útil en la investigación en educación médica.

Aplicaciones del modelamiento de ecuaciones estructurales de covarianzas

La aplicación de esta técnica estadística puede observarse en el trabajo de Austria, Cruz, Herrera y Salas en el 2012,¹⁷ donde se compararon los efectos del uso de estrategias de afrontamiento, activas y pasivas, sobre la intensidad del síndrome de *burnout* en personal de salud de dos hospitales de la Ciudad de México, con ambientes laborales distintos. El objetivo fue validar comparativamente las relaciones estructurales entre las variables de interés, de tal forma que se aportaran evidencias de validez externa sobre el papel protector que juegan las estrategias activas de afrontamiento para reducir los niveles

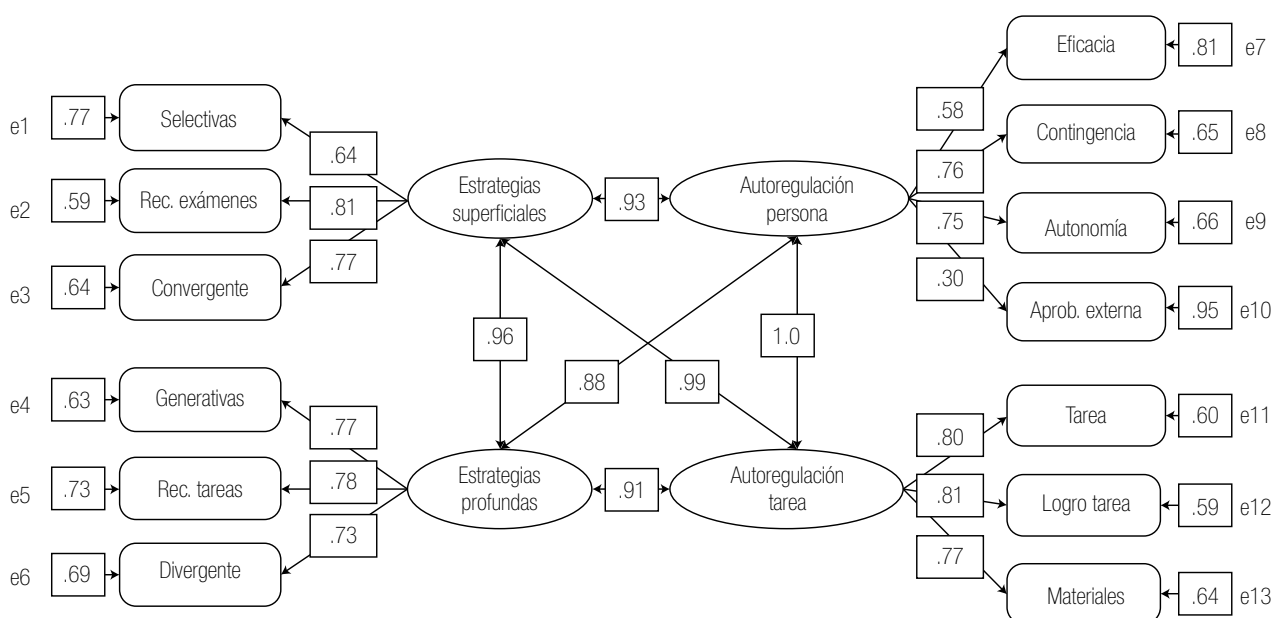


Figura 3. Ji cuadrada=313.49; $p=0.01$; CFI=0.95; RMSEA=0.06.

de síndrome de *burnout*. Los resultados de este estudio pueden apreciarse en la **Figura 4**.

A diferencia de los análisis revisados anteriormente, con esta técnica de modelación de covarianzas es posible asociar variables latentes a través de coeficientes de regresión multivariada, lo que prácticamente no es posible realizarlo con alguna otra técnica estadística.

Adicionalmente, es posible realizar comparaciones múltiples entre los parámetros del modelo, por ejemplo comparar las magnitudes de los coeficientes de regresión entre dos variables latentes en dos muestras diferentes o comparar entre dos pesos factoriales para verificar la estabilidad de un constructo en dos muestras diferentes. Este tipo de comparaciones se pueden realizar a través de la prueba estadística de multiplicadores de LaGrange que, dentro del modelamiento de ecuaciones estructurales, se utiliza principalmente para identificar los parámetros que se requiere agregar al modelo para obtener un mejor ajuste estadístico.⁴

En el ejemplo, es posible identificar las características que se mencionaron anteriormente. En primer lugar, el objetivo de los investigadores fue identificar el papel protector que juegan las estrategias activas de afrontamiento para reducir la intensidad del síndrome de *burnout*, esto es posible visualizarlo tanto en el modelo del hospital A como en el del B, donde se observa que las dos

variables latentes se encuentran asociadas a través de un coeficiente de regresión; en el caso del hospital A el coeficiente fue de $B=-0.44$, $p<0.01$, mientras que en el hospital B fue de $B=-0.42$, $p<0.01$. Obsérvese que en este caso, las estrategias de afrontamiento activas y el síndrome de *burnout* son variables latentes y están asociadas a través de una regresión multivariada.

En segundo lugar, el interés de los investigadores fue comparar si había variación significativa entre las magnitudes de los coeficientes de regresión, de esta forma si se encontraba que había variaciones significativas, entonces sería un indicador de que las estrategias de afrontamiento activas son dependientes de contexto, población y situación específica; en contraste si los resultados indicaban que no había diferencias significativas, esto aportaría evidencia de que probablemente el rol protector que juegan las estrategias activas de afrontamiento sería relativamente estable a través de contextos, personas y situaciones. Los resultados del estudio de comparación indicaron que no había diferencias significativas entre las magnitudes de los coeficientes de regresión ($X^2=3.449$; $p=0.063$).

En resumen, es posible identificar diversas ventajas prácticas que tiene el modelamiento de ecuaciones estructurales de covarianzas:

- Tiene la posibilidad de modelar efectos entre variables latentes.

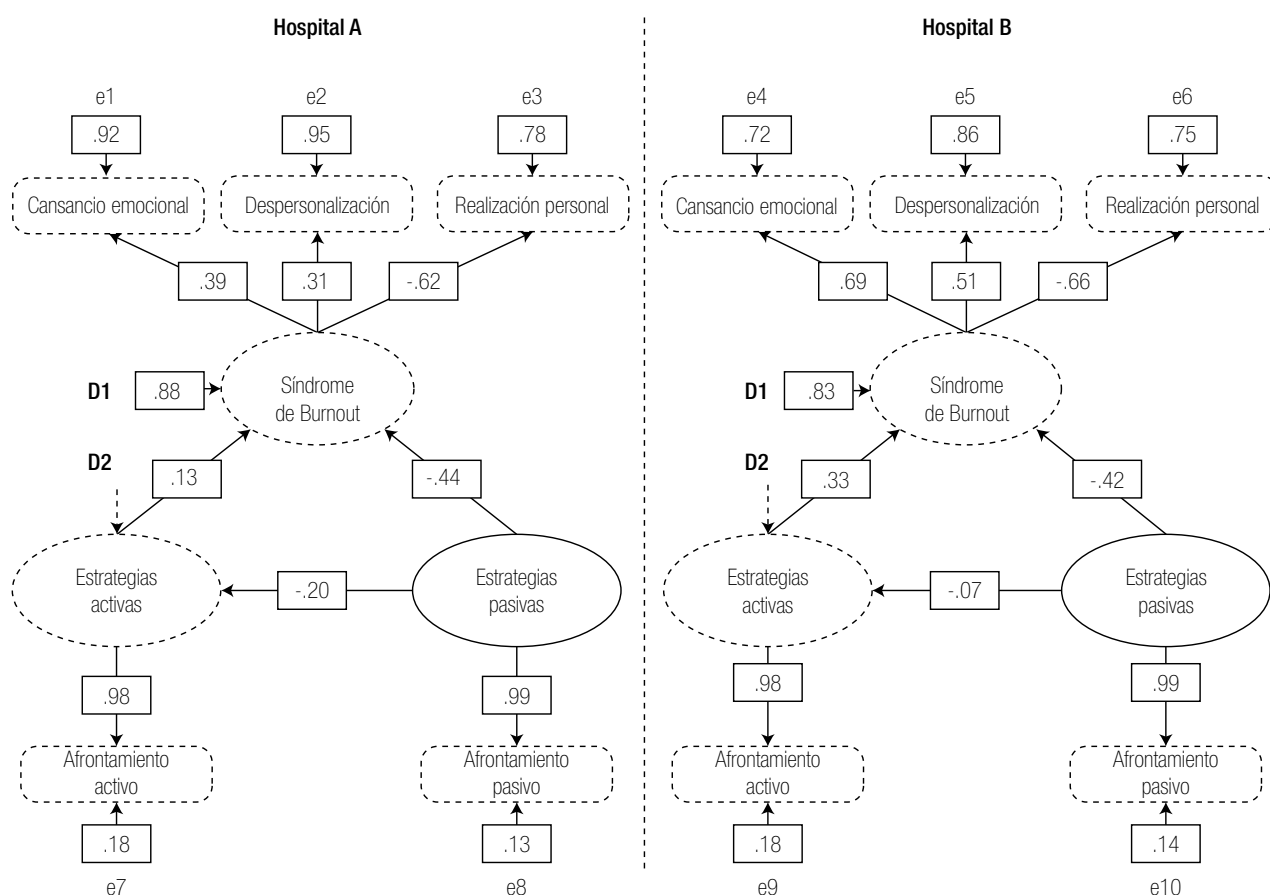


Figura 4. Ji cuadrada=31.17; $p=0.69$; CFI=1.000; RMSEA=0.001.

- Al igual que en el AFC y análisis de senderos, reduce los problemas de colinealidad de las variables independientes y posibilita estimar efectos directos, indirectos y totales de las variables involucradas en el modelo.
- Es posible realizar comparaciones entre grupos independientes y entre cualquiera de los parámetros del modelo, ya sean covarianzas, pesos factoriales o coeficientes de regresión multivariada.

Es claro que este tipo de ventajas prácticamente no es posible resolverlas o identificarlas en ninguna otra técnica estadística de naturaleza univariada.

Conclusiones

Utilizar enfoques estadísticos tradicionales univariados y unidimensionales para analizar fenómenos que teóricamente son complejos, multidimensionales, multivariados y multicausados pecaría de ingenuidad y sobre todo haría absurdo asumir que las evidencias generadas sean lo suficientemente sólidas para elaborar conclusiones. Por estas razones, los autores recomiendan utilizar aproximaciones multivariadas y multidimensionales confirmatorias que permitieran validar las relaciones que teóricamente se han propuesto, de esta forma se eliminan amenazas de validez en la conclusión estadística y mejora la validez interna en tanto que estos métodos permiten explicar las complejas relaciones entre múltiples variables, tal como sucede en las condiciones naturales.

A la fecha, la investigación educativa en general muestra pocos trabajos donde se analice el interjuego simultáneo entre variables diversas; y, en la medida en la que los problemas de la formación universitaria continúen siendo vigentes es necesario insistir en la necesidad de generar evidencias sólidas que guíen la evaluación y el fomento del aprendizaje complejo en las universidades.

Si bien es cierto que los autores presentaron aquí algunos ejemplos del modelamiento estructural de variables predictoras del aprendizaje en Medicina y del comportamiento en instituciones de salud, también es cierto que éste se convierte en un punto de inicio para proyectos futuros donde nuestro Laboratorio en conjunto con otros se comprometan en tan magna empresa. Queda ahí la invitación.

Contribución de los autores

SCF y FAC, contribuyeron en la realización total del artículo; SCF en un 60% y FAC aportó un 40%.

Financiamiento

Ninguno.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de interés.

Presentaciones previas

Ninguna.

Referencias

1. Swanwick T. Understanding medical education. Evidence, Theory and Practice. London, UK: Wiley-Blackwell; 2010.
2. Ferguson KJ. Facilitating Student Learning. En: Jeffries WB, Hugggett KN (eds). An introduction to medical teaching. New York: Springer; 2010.
3. Quirk M. Intuition and Metacognition in Medical Education: Keys to developing expertise. New York: Springer Publishing Company; 2006.
4. Kline RB. Principles and practice of structural equation modeling. Tercera edición. New York-London: The Guilford Press; 2011.
5. Crano WD y Brewer MB. Principles and methods of social research. Segunda edición. New Jersey: Lawrence Erlbaum Associates, Inc.; 2002.
6. Bentler PM. Multivariate analysis with latent variables: Causal modeling. Annual Review of Psychology 1980;31:419-456.
7. Jöreskog KG, Sörbom D. Recent developments in structural equation modeling. Journal of Marketing Research 1982;19:404-416.
8. Muthén BO. A general structural equation model with dichotomous, ordered categorical, and continuous latent variable indicators. Psychometrika 1984;49:15-132.
9. Wright S. Path coefficients and path regressions: Alternative or complementary concepts? Biometrics 1960;16(2):189-202.
10. Jöreskog KG. A general approach to confirmatory maximum likelihood factor analysis. Psychometrika 1969;34(2):183-202.
11. Jöreskog KG. Structural analysis of covariance and correlation matrices. Psychometrika 1978;43(4):443-477.
12. McGaw B, Joreskog KG. Factorial invariance of ability measures in groups differing in intelligence and socioeconomic status. British Journal of Mathematical and Statistical Psychology 1971;24:154-168.
13. Austria-Corralles F. Identificación de predictores del desempeño académico en estudiantes del curso de terapia respiratoria en el INER. Neumología y Cirugía de Tórax 2012;71(3):268-286.
14. Castañeda S, Pineda ML, Gutiérrez E, et al. Construcción de instrumentos de estudio, autorregulación y epistemología personal. Validación de constructo. Revista Mexicana de Psicología 2010;27(1):75-85.
15. Abell N, Springer DW, Kamata A. Development and Validating Rapid Assessment Instruments. New York: Oxford University Press; 2009.
16. Shadish WR, Cook TD, Campbell DT. Experimental and Quasi-experimental designs for generalized causal inference. Michigan: Houghton Mifflin; 2002.
17. Austria F, Cruz B, Herrera L, et al. Relaciones estructurales entre estrategias de afrontamiento y síndrome de burnout en personal de salud: Un estudio de validez externa y de constructo. Universitas Psychologica 2012;11(1):197-206.