

CUADERNOS DEL CIMBAGE



Universidad de Buenos Aires
Facultad de Ciencias Económicas



LOS MODELOS DE ECUACIONES ESTRUCTURALES Y SU APLICACIÓN A LA EVALUACIÓN DEL RIESGO PERCIBIDO

Autor(es): LEPERA A., MUIÑOS R.

Fuente: Cuadernos del CIMBAGE, Nº 20 (Mayo 2018), pp 85-105

Publicado por: Facultad de Ciencias Económicas de la Universidad de Buenos Aires.

Vínculo: <http://ojs.econ.uba.ar/ojs/index.php/CIMBAGE/issue/view/173>



Esta revista está protegida bajo una licencia Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0).

Copia de la licencia: <https://creativecommons.org/licenses/by-nc-sa/4.0/>



Cuadernos del CIMBAGE es una revista académica semestral editada por el **Centro de Investigaciones en Metodologías Básicas y Aplicadas a la Gestión** (CIMBAGE) perteneciente al Instituto de Investigaciones en Administración, Contabilidad y Métodos Cuantitativos para la Gestión (IADCOM).

LOS MODELOS DE ECUACIONES ESTRUCTURALES Y SU APLICACIÓN A LA EVALUACIÓN DEL RIESGO PERCIBIDO

Andrea Lepera*, Roberto Muiños**

Maestría en Generación y Análisis de Información Estadística

Universidad Nacional de Tres de Febrero

Viamonte 783 3° Piso-CABA- C1053ABK-Argentina

*andrealopera@gmail.com, **rmuin@fibertel.com.ar

Recibido 30 de septiembre de 2016, aceptado 20 de diciembre de 2016

Resumen

La investigación cuantitativa requiere de la utilización de métodos estadísticos. El investigador, en general, parte de un modelo teórico y recoge la información necesaria para validarlo. Sin embargo, las características descriptivas o exploratorias de la mayoría de los modelos estadísticos que evalúan la interacción entre varias variables simultáneamente, dificultan esta tarea. Los modelos de ecuaciones estructurales (SEM, según sus siglas en inglés), por su carácter confirmatorio, permiten utilizar datos empíricos para evaluar la validez del modelo teórico considerado.

Los modelos SEM expresan la relación entre distintas variables, las cuales pueden ser directamente observables o no observables. Muchos de los modelos estadísticos más utilizados pueden considerarse casos particulares de SEM, incluyendo regresión lineal, análisis de correlación canónica, Path análisis, y el análisis factorial confirmatorio. Sin embargo, algunas características del SEM lo distinguen claramente tanto de los modelos univariados como de los multivariados. Las técnicas multivariadas se limitan a examinar las relaciones entre dos o más variables observables, sin posibilidad de considerar variables hipotéticas, no observables directamente. La mayoría de estas técnicas son de carácter exploratorio: buscan patrones generales definidos por los propios datos observados. El SEM es de carácter confirmatorio: el diseño de relaciones entre las variables debe ser explicitado a priori sobre la base de expectativas teóricas. Esta característica distintiva del método lo hace especialmente adecuado para testear modelos teóricos mediante la utilización de datos empíricos.

En este trabajo se presentan las principales características teórico-conceptuales de los Modelos de Ecuaciones Estructurales, conjuntamente con una aplicación a una investigación psicológica.

Palabras clave: Modelos de Ecuaciones Estructurales, Percepción del Riesgo, Factores Latentes.

STRUCTURAL EQUATIONS MODELS AND THEIR APPLICATION TO RISK PERCEPTION

Andrea Lepera*, Roberto Muiños**

Maestría en Generación y Análisis de Información Estadística

Universidad Nacional de Tres de Febrero

Viamonte 783 3° Piso-CABA- C1053ABK-Argentina

*andrea.lepera@gmail.com, **rmuin@fibertel.com.ar

Received September 30th 2016, accepted December 20th 2016

Abstract

Quantitative research requires the use of statistical methods. Generally, a researcher starts from a theoretical model and gathers the necessary information to validate it. However, the descriptive or exploratory characteristics of most statistical models which evaluate interaction among a number of variables simultaneously render this task more difficult. Structural equation models (SEM), given their confirmatory nature, allow for the use of empirical data to evaluate the validity of the theoretical model considered.

SEMs express the relationship among a few variables, which can either be directly observable or not observable at all. Many of the most widely used statistical models may be considered particular cases of SEM, including linear regression, canonical correlation analysis, path analysis, and confirmatory factor analysis. Nonetheless, some of SEM characteristics clearly distinguish it from both the univariate and the multivariate models. Multivariate techniques only examine the relationships between two or more observable variables, providing no possibility to consider hypothetical, non-observable variables. Most of these techniques are exploratory, i.e., they look for general patterns defined by the observed data itself. The SEM is of a confirmatory nature, i.e., the design of relationships among variables must be previously made explicit on the basis of theoretical expectations. This distinctive feature makes this method especially adequate for testing theoretical models through the use of empirical data.

This paper presents the main theoretical-conceptual characteristics of Structural Equation Models, along with their application to a psychological research.

Keywords: Structural Equation Models, Latent Factors, Risk Perception.

INTRODUCCIÓN

El concepto de “Modelos de Ecuaciones Estructurales” o “SEM” (por sus siglas en inglés: *Structural Equations Modeling*) designa un conjunto de procedimientos y técnicas de Estadística Multivariada que incluyen una gran cantidad de métodos clásicos, entre otros, a la Regresión Lineal, el Análisis Factorial Exploratorio y Confirmatorio y el Análisis de Senderos (*Path Analysis*).

Sin embargo, su principal característica es la posibilidad de incluir variables no observables en una variedad mucho más amplia de modelos. De esta manera, se constituye en una herramienta clara y objetiva para la contrastación empírica de hipótesis teóricas, siendo utilizada en diversas disciplinas como Economía, Psicología, Sociología, Educación, Marketing, etc. (Gogni y Muiños (2016), Orlandoni (2007), Segovia-Vargas *et al.* (2015), Poza Lara y Fernández Cornejo (2011)). En todos estos campos es usual el empleo de constructos teóricos, o sea variables no observables directamente, también llamadas latentes, de los cuales sólo se cuenta con indicadores o variables *proxy* que sí pueden medirse sobre las unidades de análisis y constituyen la única información disponible. Los Modelos de Ecuaciones Estructurales permiten establecer relaciones complejas entre variables observables y latentes mediante modelos estadísticos que luego pueden ser evaluados tanto en forma global como específica.

En este trabajo se presenta el desarrollo conceptual y teórico de los modelos SEM y una aplicación del mismo al análisis de la Percepción del Riesgo.¹

En la Sección 1 se describen los conceptos básicos de los Modelos de Ecuaciones Estructurales, incluyendo la terminología y nomenclatura usual. En la Sección 2 se exponen las etapas del modelo, que incluyen la estimación de los parámetros involucrados y la evaluación del ajuste. En la Sección 3 se presenta el Modelo de Percepción de Riesgo desarrollado por Rohrmann (Rohrmann, 1994) y los resultados obtenidos al replicar el mismo en un estudio realizado en Argentina (Mikulic y Muiños *et al.*, 2012).

Finalmente, en la Sección 4 se exponen las conclusiones y consideraciones finales en cuanto a las posibilidades de aplicación de estos modelos.

¹ Los datos fueron suministrados por los investigadores del Proyecto UBACyT 20020130100292BA (2014-2017): “Inteligencia Emocional y Calidad de Vida: Estudio de las Competencias Socioemocionales en Contextos Naturales”, dirigido por la Dra. Isabel Mikulic de la Facultad de Psicología de la Universidad de Buenos Aires.

1. MODELO DE ECUACIONES ESTRUCTURALES

1.1. Modelo de Medición y Modelo de Variables Latentes

En las ciencias del comportamiento los investigadores suelen estudiar constructos teóricos que no pueden observarse directamente. Las variables latentes (también llamadas factores o no medibles) son aquellas que remiten a dichos constructos. Al tratarse de variables que no pueden observarse directamente, tampoco son susceptibles de ser medidas, por lo cual el investigador debe operacionalizarlas en términos de variables observables (también llamadas indicadores, medidas, manifiestas o variables Proxy) que las representen (Byrne, 2010).

Los cambios en las variables latentes producen efectos en sus indicadores, cuya modelización se conoce como “Modelo de Medición”.

La relación entre los constructos o variables latentes, puede manifestarse entonces a través de una relación entre sus respectivos indicadores. Es decir que en la relación manifiesta entre variables observables subyace la relación estructural entre estos fenómenos abstractos, lo que da lugar al “Modelo de Variables Latentes”.

El conjunto de ecuaciones de ambos Modelos (de Medición y de Variables Latentes) conforman el “Sistema de Ecuaciones Estructurales” o “Modelo SEM” (por sus siglas en inglés *Structural Equations Models*). En cada ecuación se plantea el comportamiento de una variable, denominada endógena, en función de otra u otras que la explican, llamadas exógenas, mediante una relación lineal en los parámetros, de manera similar al Modelo Clásico de Regresión.

El modelo completo involucra variables aleatorias (latentes, observadas y perturbaciones), parámetros y, eventualmente, variables no aleatorias (variables explicativas que tienen siempre el mismo valor en muestreos repetidos). Los parámetros son constantes que proveen la relación entre variables latentes, entre variables observadas o entre variables latentes y observadas (Bollen, 1989).

2. DIAGRAMA DE SENDEROS O PATH DIAGRAM

El Diagrama de Senderos o *Path Diagram* es una representación visual de las relaciones entre variables latentes y/o sus correspondientes indicadores mediante grafos.

Las convenciones de este diagrama son las siguientes (Batista Foguet y Coenders Gallart, 2000):

1. La relación causal entre variables se representa por una flecha orientada desde la variable causa hacia la variable efecto. Dicha flecha está afectada por un parámetro o coeficiente *path* que indica la magnitud de dicho efecto. Si no se incluye flecha entre dos variables se asume que la magnitud de su relación es 0. Todas las variables endógenas reciben al menos una flecha y las variables exógenas no reciben flecha alguna.

2. Las variables latentes se enmarcan en elipses y las observables en rectángulos. En particular las perturbaciones (cuyo significado es análogo al del modelo clásico de Regresión Lineal), al tratarse de un caso particular de variable latente, se incluyen en el diagrama dentro de un círculo.

3. La covariación entre dos variables se indica mediante una flecha bidireccional que las une.

En la Figura 1 se detallan los símbolos usados en el Diagrama de Senderos (Bollen, 1989)




Figura 1: Simbología empleada en el *Path Diagram* ²

² Elaboración propia a partir de Bollen (1989)

La notación habitual para los distintos tipos de variables involucradas en los Modelos SEM es la siguiente:

- Variables observables: las endógenas se notan con la letra X y las exógenas con la letra Y.
- Las matrices de coeficientes de X e Y se denotan por Λ_X y Λ_Y , respectivamente.
- Variables latentes: las endógenas se notan con η y las exógenas con ξ
- Las matrices con los coeficientes de η y ξ se denotan B y Γ , respectivamente.
- Perturbaciones: las incluidas en el modelo de medición son denominadas δ para los indicadores X y ε para los indicadores Y. Las correspondientes al modelo de variables latentes, se notan con ζ .

Cada uno de los símbolos del Diagrama de Senderos se corresponde con alguna ecuación del Modelo. Por ejemplo, las ecuaciones correspondientes al siguiente *Path Diagram* de la Figura 2. son las expresadas en (1)




Figura 2: Ejemplo de *Path Diagram*

$$(1) \{X_1 = \lambda_{11}\xi_1 + \delta_1 X_2 = \lambda_{21}\xi_1 + \delta_2$$

O bien, en forma matricial:

$$X = \Lambda\xi + \delta$$

3. ETAPAS DEL MODELO

3.1. Planteo e Identificación del Modelo

En general, un Modelo de Ecuaciones Estructurales, se expresará de manera matricial como:

$$\{\eta = B\eta + \Gamma\xi + \zeta \quad X = \Lambda_X \xi + \delta \quad Y = \Lambda_Y \eta + \varepsilon$$

con los supuestos que se detallan a continuación:

$$E(\eta) = 0 \quad E(\xi) = 0 \quad E(\zeta) = 0 \quad E(\delta) = 0 \quad E(\varepsilon) = 0$$

$\eta, \xi, \zeta, \delta, \varepsilon$ no correlacionadas entre sí

Los parámetros del Modelo resultan ser, entonces:

$$B \quad \Gamma \quad \Lambda_X \quad \Lambda_Y$$

y las matrices de covarianzas:

$$\Phi = E(\xi \cdot \xi') \quad \Psi = E(\zeta \cdot \zeta') \quad \Theta_\delta = E(\delta \cdot \delta') \quad \Theta_\varepsilon = E(\varepsilon \cdot \varepsilon')$$

A partir de las ecuaciones y los supuestos del modelo, puede expresarse la Matriz de Covarianzas Poblacional Σ de X e Y en función de los parámetros del modelo, llamada Matriz de Covarianza Implícita $\Sigma(\Theta)$ (donde $\Theta = (B, \Gamma, \Lambda_X, \Lambda_Y, \Phi, \Psi, \Theta_\delta, \Theta_\varepsilon)$ representa el vector de parámetros del modelo).

Se considera que el modelo está “Identificado” o es “Identificable”, cuando pueden determinarse los parámetros en forma unívoca en función de los coeficientes no redundantes de la matriz de Covarianzas Σ . Al respecto Bollen (1989) afirma:

“Si un parámetro desconocido en Θ puede ser escrito como una función de uno o más elementos de Σ , los parámetros son identificados. Si todos los parámetros desconocidos en Θ son identificados, entonces el modelo es identificado.” (p.89)

Entre las condiciones de Identificación de un Modelo SEM, se encuentran la Regla-t, Recursividad y B nula.

La Regla-t es una condición necesaria de Identificabilidad, en la que la cantidad t de parámetros a estimar no puede superar la cantidad k de

varianzas y covarianzas no redundantes entre las variables observadas X e Y. Es decir, si p es la cantidad de variables X y q la cantidad de variables Y, entonces:

$$t \leq k = \frac{(p+q)(p+q+1)}{2}$$

La diferencia entre estos dos valores se conoce como grados de libertad del Modelo y se denota df por sus siglas en inglés (*degrees of freedom*)

$$df = \frac{(p+q)(p+q+1)}{2} - t$$

con lo cual la Regla -t señalaría que un modelo con grados de libertad negativos no es identificable.

Un Modelo se dice Recursivo si cada variable endógena η_k no es exógena en las ecuaciones siguientes, o sea no es explicativa de las variables η_j con $j \geq k$. En este caso la matriz B de coeficientes de η es triangular inferior. Un caso particular es cuando ninguna variable endógena η es exógena, lo que resulta en una matriz B nula.

La condición de que B sea nula y la de Recursividad son condiciones suficientes de Identificabilidad del Modelo (Bollen, 1989)

3.2. Estimación

Una vez que el Modelo se sabe Identificable, la estimación de los parámetros surge de minimizar alguna función de discrepancias F (S, $\Sigma(\Theta)$) entre la matriz de Covarianza Muestral S de las variables observadas y la Matriz de Covarianza Implícita $\Sigma(\Theta)$.

Las funciones de discrepancia más usuales son (Bollen, 1989):

- Máxima Verosimilitud o *Maximum Likelihood* (ML)

$$F_{ML} = \log(|O|) + \text{tr}(S^{-1}O) - \log(|S|) - (p+q)$$

- Mínimos Cuadrados Generalizados o *Generalized least squares* (GLS)

$$F_{GLS} = \frac{1}{2} [(S - O) \quad \quad \quad]^{-1} \quad \quad \quad]$$

En este último caso la matriz W^{-1} es la matriz de Pesos o Ponderaciones, cuya elección usual es $W=S$. Si se considera $W=I$ la función resulta ser la de Mínimos Cuadrados No Ponderados.

- Mínimos Cuadrados No Ponderados o *Unweighted least squares* (ULS)

$$F_{ULS} = \frac{1}{2} [(S - O) \quad \quad \quad]$$

Cuando las variables observadas tienen distribución Normal Multivariada, suele emplearse la Función de Máxima Verosimilitud.

3.3. Evaluación

Una vez realizada la estimación de los parámetros, el investigador estará interesado en interpretar los resultados obtenidos, como así también evaluar el ajuste y comparar distintos Modelos. Los aspectos considerados por los indicadores de la bondad del ajuste se basan en la medida de la discrepancia entre la matriz de Covarianzas Implícita evaluada en los parámetros estimados y la Muestral (notadas $\hat{\Sigma} = (\hat{\Theta})$ y S respectivamente) la parsimonia del modelo y la dispersión de los parámetros estimados. En la literatura se recomienda el informe de múltiples indicadores, que tengan en cuenta los distintos aspectos mencionados, los cuales pueden agruparse en Índices de Ajuste Absoluto, Índices de Ajuste Incremental e Índices de Parsimonia (Hooper *et al.*, 2008).

En muchos casos los índices se basan en la comparación del ajuste obtenido por el modelo empleado con el “Modelo de Independencia” (también llamado Base o *Baseline*) y con el “Modelo Saturado”. En el Modelo Base se asume que todos los *path* están fijos en 0, o sea que las variables involucradas son independientes. Este es el modelo más restrictivo y posee el mayor valor posible de grados de libertad *df*.

En el otro extremo, el Modelo Saturado incluye todos los *path* posibles, resultando ser el modelo menos restrictivo, con *df*=0.

3.3.1. Índices de Ajuste Absoluto

Los índices de Ajuste Absoluto son indicadores de qué tan bien (o tan mal) ajusta el modelo hipotético a los datos muestrales.

- CHI CUADRADO

El índice tradicional es el χ^2 que mide qué tan “malo” es el ajuste, considerándose apropiado cuando se obtienen valores no significativos del estadístico. En el caso de que las variables tengan distribución normal multivariada y se realice la estimación mediante la Función de Discrepancia de Máxima Verosimilitud, se tiene que

$$CMIN = (N - 1) : \frac{\chi^2}{df}$$

En la mayoría de los *softwares* que incluyen la modelización SEM suele informarse el valor de CMIN conjuntamente con el nivel de significación. Cabe destacarse que este estadístico suele tener severas limitaciones en cuanto al supuesto de normalidad y resulta ser muy sensible al tamaño muestral (Hooper *et al.*, 2008). Para minimizar el

efecto del tamaño de la muestra se recomienda el índice Chi cuadrado Normado $\frac{CMIN}{df}$.

- RMSEA

Otro índice de ajuste absoluto es el Índice Raíz Cuadrada Media del Error de Aproximación RMSEA (por sus siglas en inglés *Root Mean Square Error of Approximation*) (Browne & Cudeck, 1993). Se define como

$$RMSEA = \sqrt{\frac{NCP}{(N-1)df}} \quad \text{donde } NCP = \{CMIN - df, 0\}$$

Como el valor CMIN se basa en la discrepancia entre $\hat{\Sigma} = \Sigma(\hat{\theta})$ y S, constituye un estimador sesgado del error de aproximación, que es la discrepancia entre $\Sigma(\hat{\theta})$ y Σ . El índice RMSEA tiene en consideración esta situación, al incluir en su cálculo el parámetro de no centralidad del Modelo NCP.

Una ventaja de este índice es la posibilidad de contar con intervalos de confianza (la mayoría de los softwares informan los intervalos con nivel de confianza 0,90), recomendándose como indicadores de un buen ajuste que el límite superior de dicho intervalo tome un valor inferior a 0,08.

- GFI y AGFI

El Índice de Bondad de Ajuste *Goodness of Fit Statistic* GFI se define (para la función de ajuste F_{ML}) como

$$GFI = 1 - \frac{CMIN_M}{CMIN_b}$$

donde $CMIN_M$ y $CMIN_b$ son los valores CMIN del modelo en estudio y el modelo Base, respectivamente.

El Índice de Bondad de Ajuste Corregido AGFI (*Adjusted Goodness of Fit Statistic*) se define en función del GFI como

$$AGFI = 1 - \frac{k}{df} (1 - GFI)$$

donde k es la cantidad de coeficientes no redundantes de S (Bollen, 1989).

Ambos índices toman valores en el rango 0-1, recomendándose como indicadores de buen ajuste, valores superiores a 0,90 (Hooper *et al.*, 2008)

- RMR y SRMR

La Raíz Cuadrada de la Media Cuadrática Residual (RMR, por sus siglas en inglés *Root Mean Square Residual*) se define como

$$RMR = \left[2 \sum_{i=1}^k \sum_{j=1}^i \frac{(\hat{\theta}_{ij})^2}{(k+1)} \right]^{1/2}$$

Donde $\hat{\theta}_{ij}$ es el coeficiente ij de la matriz $\hat{\Sigma} = \Sigma(\hat{\theta})$ que minimizó la función de discrepancia.

Una desventaja de este índice es que se computa con variables no estandarizadas, por lo que su valor depende de la escala de las variables observadas. El Cuadrado Medio Residual Estandarizado o *Standardised Root Mean Square Residual* (SRMR) se computa de manera análoga al RMR, pero a partir de las matrices de Correlación (Kline, 2011).

Los valores del SRMR se encuentran en el rango 0-1. La literatura recomienda valores de SRMR inferiores a 0,05 como indicadores de un buen ajuste, pero considera aceptables valores de hasta 0,08 (Hooper *et al.*, 2008).

3.3.2. Índices de Ajuste Incremental

Los índices de Ajuste Incremental, también llamados Relativos, comparan el modelo planteado con el Modelo Base o de Independencia, considerando como Hipótesis Nula que las variables son incorrelacionadas.

- NFI

El índice de Ajuste Normado o NFI por sus siglas en inglés *Normed Fit Index*, es:

$$NFI = \frac{(N-1) - (N-1)F_M}{(N-1)F_b} = 1 - \frac{F_M}{F_b}$$

donde F_M y F_b son los valores mínimos de la función de discrepancia empleada en la estimación de los parámetros del Modelo en estudio y del Base, respectivamente (Bentler, 1990).

El rango de este índice es entre 0 y 1, donde 0 corresponde al modelo de independencia. Por lo tanto, un buen ajuste estaría asociado a un valor alto de NFI. La literatura recomienda valores superiores a 0,95. La desventaja de este indicador es que resulta inapropiado cuando el tamaño muestral es menor a 200 (Hooper *et al.*, 2008).

- TLI

El Índice TLI o *Tucker-Lewis Index*, también conocido como NNFI (*Non Normed Fit Index*) se define como (Arbuckle, 2013):

$$TLI = \frac{\frac{F_b}{df_b} - \frac{F_M}{df_M}}{\frac{F_b}{df_b} - \frac{1}{N-1}}$$

Si bien es usual que este índice tome valores entre 0 y 1, no tiene un rango específico. La literatura sugiere que valores cercanos a 1 serían indicadores de un ajuste apropiado. Hu y Bentler (1999) recomiendan como punto de corte el valor 0,95.

- CFI

El Índice de Ajuste Comparado CFI (*Comparative Fit Index*) se define como 1 para aquellos modelos donde $C_M \leq df_M$ o

$$CFI = 1 - \frac{C_M - df_M}{C_b - df_b}$$

para los demás casos (Kline, 2011).

Este índice tiene en consideración el coeficiente de no centralidad del modelo en estudio y del de independencia. Su valor 1 no es indicador de un buen ajuste sino de que $C_M \leq df_M$. El punto de corte recomendado como indicador de buena especificación del modelo hipotético es 0,95 (Hooper *et al.*, 2008).

3.3.3. Índices de Parsimonia

Frente a modelos hipotéticos diferentes que ajustan de manera similar a los datos, el investigador elegirá aquel que sea más simple. Por lo cual los índices de Parsimonia penalizan el exceso de parámetros a estimarse.

- AIC

El AIC (*Akaike Information Criterion*) o Criterio de Información de Akaike se define como la suma de CMIN y el doble de la cantidad de parámetros a estimar por el modelo:

$$AIC = CMIN + 2t$$

En general este índice se utiliza para comparar distintos modelos basados en las mismas variables y mismos datos, pero con distinta cantidad de parámetros. Los *softwares* generalmente informan el índice AIC del modelo propuesto conjuntamente con los correspondientes al modelo de Independencia y al modelo Saturado. Cuanto más cercano a 0 (valor mínimo) sea AIC, mejor se considera el modelo.

- PNFI

El índice PNFI es el producto del índice NFI mencionado anteriormente y el PRATIO, siendo éste último el cociente entre los grados de libertad del modelo en estudio y los del modelo de independencia. Es decir:

$$PNFI = NFI \cdot PRATIO = NFI \cdot \frac{df_M}{df_b}$$

Al igual que el índice de Akaike, el PNFI no tiene un valor de referencia que indique un buen ajuste. Los autores aconsejan el empleo de los índices de parsimonia conjuntamente con los demás índices de ajuste, ya que su valor por sí solo, no permite sacar conclusiones acerca de la bondad del ajuste (Hooper *et al.*, 2008).

Dada la complejidad de análisis de bondad del ajuste, los expertos sugieren informar varios indicadores, contemplando los diversos aspectos considerados.

El valor Chi cuadrado suele informarse ya que, aún con sus debilidades, es un indicador esencial; se recomienda su reporte conjuntamente con el P-valor y con los grados de libertad.

Hu y Bentler (1999) sugieren distintas combinaciones de dos índices, cuyo resumen y valores de referencia se presentan en la Figura 3. (Hooper *et al.*,2008).

Combinación de Índices de Ajuste	Reglas de combinación	
NNFI y SRMR	NNFI > 0,96	SRMR < 0,09
RMSEA y SRMR	RMSEA < 0,06	SRMR < 0,09
CFI y SRMR	CFI > 0,96	SRMR < 0,09

Figura 3: Combinación de Índices de Ajuste sugeridos por Hu y Bentler (1999) ³

4 APLICACIÓN DE UN MODELO SEM AL ESTUDIO DE LA PERCEPCIÓN DEL RIESGO

4.1. Percepción del Riesgo

El término Percepción del Riesgo refiere al juicio, opinión o creencia de las personas acerca de cuán grande es el riesgo asociado a un peligro (Rohrman, 2002).

³ Elaboración propia en base a Hooper *et al.* (2008).

El mismo autor (Rohrmann, 2008) define la percepción de riesgo “*como los juicios y evaluaciones que realizan las personas sobre los peligros a los que se encuentran o se podrían encontrar expuestas, los bienes o los entornos*”. Los estudios psicológicos y sociológicos desarrollados sobre los factores subyacentes a la percepción de riesgo han puesto de manifiesto que una multiplicidad de factores son los que inciden en la manera en que las personas perciben, evalúan y manejan riesgos. Los estudios actuales sobre percepción de riesgo ponderan este aspecto señalando la importancia de utilizar análisis multivariados para evaluar dicho constructo. En el presente trabajo se consideró un Modelo de Ecuaciones Estructurales para evaluar la percepción de riesgo, dado que permite expresar la relación entre distintas variables, las cuales pueden ser directamente observables o no observables (latentes).

4.2. Modelo de Rohrmann replicado en Argentina

Uno de los modelos teóricos de mayor reconocimiento en las investigaciones sobre la evaluación de riesgo es el propuesto y validado por Rohrmann (1994) en Australia. Ha sido replicado en diversos países, como por ejemplo Alemania, Nueva Zelanda, Chile, Brasil y China.

El modelo propone que la evaluación del riesgo por parte de los individuos se basa en la interrelación de las siguientes variables: Actitud Ecológica, Impactos Adversos, Riesgo como Amenaza, Beneficios de la Tecnología y Aceptación del Riesgo.




Figura 4: Diagrama del Modelo Estructural de la Percepción del Riesgo⁴


Actitud Ecológica (ECOL) es definida por el autor como aquella que supone una implicación deliberada sobre la protección y la calidad del medio ambiente caracterizada por maximizar la protección y reducir el deterioro del ambiente al mínimo. Se entiende por Impactos Adversos (ADV IMP) a la preocupación sobre el impacto de la tecnología en la vida de las personas, siendo los peligros tecnológicos considerados como amenazas, incluyéndose en éstas la probabilidad de morir y la preocupación por el daño para la salud. Riesgo como Amenaza (R AT TH) se define como la magnitud de riesgo asociada a los peligros posibles o a las consecuencias negativas de aquellas actividades que causan accidentes o deterioro sobre la salud. Beneficios de la Tecnología (B TECHN) es conceptualizada como la utilidad y los beneficios que algunas actividades tienen para la sociedad en general, incluyendo las posibles ventajas ligadas a las mismas. Aceptación del Riesgo (R ACCEP) es definida como el grado en que la sociedad en general está dispuesta a aceptar las consecuencias negativas de aquellas actividades que causan accidentes o deterioro sobre la salud. Todas las variables mencionadas corresponden a constructos teóricos no medibles directamente. Mikulic, Muiños *et al.* (2012) propusieron la evaluación de este modelo teórico en la República Argentina. Para obtener información sobre estas variables se utilizó la adaptación

⁴ Elaboración propia en base al *Path Diagram* presentado por Rohrmann (1994).

Argentina (Mikulic, Muiños *et al.*, 2009) del Hazard Evaluation Questionnaire (Rohrmann, 2005) del que se consideraron las siguientes escalas: PD: Probabilidad de morir, HI: Impacto sobre la salud, RM: Magnitud del riesgo, CP: Número, esperado de víctimas, FA: Sentimientos de ansiedad, AEC: Actitud hacia problemáticas ambientales, AIT: Actitud hacia el impacto de la tecnología moderna, ASV: Actitud hacia orientaciones de valor social, SB: Beneficio social, SA: Aceptación social del riesgo. Estas escalas constituyeron las variables observables que permiten contar con información de los constructos latentes mencionados en el párrafo anterior. Este instrumento se aplicó a una muestra intencional de 470 personas, con edades entre 19 y 65 años, integrada por 46.2 % de hombres y 53.8 % de mujeres. El grupo de participantes estaba integrado por 250 estudiantes y docentes pertenecientes a distintas instituciones educativas públicas de la Ciudad de Buenos Aires (de Psicología, Geografía, Ciencias Ambientales e Ingeniería) y 220 individuos de ambientes no académicos (amas de casa, empresarios, empleados y desocupados).

4.3. Estimación del Modelo y Evaluación del Ajuste

Las estimaciones del modelo aplicado se llevaron a cabo utilizando el procedimiento AMOS de SPSS versión 21.



GFI	0.964
AGFI	0.936
CFI	0.927
RMSEA	0.063 (0.047;0.078)
SRMR	0.0609

Figura 5: Estimaciones de los Parámetros Estandarizados e Indicadores de Bondad de Ajuste del Modelo de Percepción del Riesgo (Fuente: Elaboración Propia)

La Figura 5 muestra la relación propuesta entre los factores latentes y las variables observables obtenidas mediante la aplicación del formulario Hazard Evaluation Questionnaire (Rohrmann, 2005) y los estimadores estandarizados obtenidos en el ajuste estadístico a los datos de la muestra local mencionada. Con el fin de evaluar si los datos obtenidos respaldan el modelo teórico en estudio, se utilizaron los siguientes índices de bondad de ajuste: a) Índice de Bondad de Ajuste

(GFI), b) Índice de Ajuste Comparado (CFI), c) Índice de Bondad de Ajuste Corregido (AGFI) y, d) Índice de la Raíz Cuadrada Media del Error de Aproximación (RMSEA). Si bien, como se ha señalado anteriormente, no existe total consenso respecto a cuáles son los indicadores de bondad de ajuste a informar, se optó por incluir los mismos que fueran reportados por el Prof. Rohrmann en su estudio, a los efectos de reforzar la comparación con el modelo validado por el mismo. Los valores obtenidos en los índices de ajuste son aceptables de acuerdo a los criterios reportados por Hu y Bentler (1999). En términos generales, los resultados obtenidos al evaluar la percepción de riesgo en el contexto sociocultural de la muestra correspondiente a la Ciudad de Buenos Aires muestran correspondencia con los reportados por Rohrmann (1994), al poner a prueba el mismo modelo conceptual en Australia y en otros países como Alemania y Nueva Zelanda. Se verifica que, cuanto mayor es el impacto negativo que se atribuye a la tecnología sobre la vida de las personas (mayor probabilidad de morir y/o de efectos negativos sobre la salud), mayor es el riesgo como amenaza (magnitud de riesgo asociada a los posibles peligros), y menor la aceptación social del riesgo. Si bien la variable exógena Actitud Ecológica no tiene efectos directos significativos sobre la Percepción del Riesgo como Amenaza y sobre la variable Beneficios de la Tecnología, la misma ha sido considerada con el fin de mostrar las diferencias con otras culturas.

5. CONCLUSIONES

En este trabajo se han desarrollado la teoría y los conceptos principales de los Modelos de Ecuaciones Estructurales (modelos SEM). De acuerdo a lo observado, la característica más destacada de los Sistemas de Ecuaciones Estructurales es la posibilidad de ajustar y evaluar modelos que incluyan tanto variables observables como variables latentes, pudiendo estimarse inclusive relaciones similares a las de la Regresión Lineal Clásica entre las variables no observables.

El carácter confirmatorio de esta metodología viene dado por el requerimiento de que el investigador proponga un modelo teórico que será luego contrastado a partir de la información disponible. De esta manera, a diferencia de la estrategia más extendida de pretender que los datos empíricos provean el modelo a ajustar, se propone la modelación estadística para determinar, a partir de los datos muestrales, la validez de los supuestos teóricos.

Con respecto a la modelación de la Percepción del Riesgo en una muestra local, los indicadores de bondad de ajuste presentan niveles

aceptables que permiten considerar la validez del modelo en nuestro medio.

Las aplicaciones de los modelos SEM en nuestro país se encuentran fundamentalmente en el campo de la Psicología y de las Ciencias Sociales (artículos ya citados de Mikulic- Muiños y Gogni-Muiños, entre otros). Pero en otros países, pueden encontrarse también aplicaciones en el ámbito de la Economía. Orlandoni (2007) utiliza la metodología SEM para determinar indicadores que permitan evaluar los distintos tipos de riesgo a los que se encuentran expuestas las instituciones bancarias (riesgo de crédito, de liquidez, operacional, de mercado), vinculándolos con los factores macroeconómicos. Poza Lara y Fernández Cornejo (2011) utilizaron los Modelos de Ecuaciones Estructurales para determinar los factores que explican la pobreza multidimensional en España. Asimismo, Segovia Vargas *et al.* (2015) aplican los métodos SEM al análisis del riesgo en los seguros automotores.

Asumir que existen constructos que sólo pueden ser medidos mediante variables Proxy o indicadores parciales, implica reconocer que la metodología estadística tradicional tiene limitadas posibilidades para su modelización. Los Sistemas de Ecuaciones Estructurales aparecen, entonces, como una metodología más adecuada para estos casos por su capacidad de modelar relaciones que incluyan tanto variables observables como variables latentes.

BIBLIOGRAFÍA

Arbuckle, J. L. (2013). IBM SPSS Amos 22 user's guide. Crawfordville, FL: Amos Development Corporation, 635.

Batista Foguet, J. M. y Coenders Gallart, G. (2000). Modelos de ecuaciones estructurales: modelos para el análisis de relaciones causales. La Muralla.

Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological bulletin*, 107(2), 238.

Bollen, K. A. (1989). *Structural equations with latent variables*. John Wiley & Sons.

Byrne, B. M. (2010). *Structural equation modeling with AMOS: Basic concepts, applications, and programming*. Routledge/Taylor & Francis Group.

Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. *Sage focus editions*, 154, 136-136

Gallart, G. C., Saris, W. E., & Foguet, J. M. B. (2005). *Temas avanzados en modelos de ecuaciones estructurales*. La Muralla.

Gogni, V. y Muiños, R. (2016). Aplicación de un Modelo Factorial Confirmatorio para Encontrar los Factores Latentes que Determinan la Calidad de Vida Percibida. *Revista de Matemática: Teoría y Aplicaciones* 2016 23(2): 463-473. CIMPA – UCR ISSN: 1409-2433 (PRINT), 2215-3373 (ONLINE)

Hooper, D., Coughlan, J., y Mullen, M. (2008). *Structural equation modelling: Guidelines for determining model fit*. *Articles*, p. 2.

Hu, L. T., y Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural equation modeling: a multidisciplinary journal*, 6(1), 1-55.

Kline, R. B. (2011). *Principles and Practice of Structural Equation Modeling*. Guilford Press.

Mikulic, I. M., Muiños, R., Cassullo, G. L., Albornoz, O., Marconi, A., Fernandez, G., Ojeda, G. M., Torcassi, V. (2009). *Psicología Ambiental y Evaluación Psicológica: Aportes de las Técnicas Psicométricas a la Evaluación de la Percepción del Riesgo*. In I Congreso Internacional de Investigación y Práctica Profesional en Psicología XVI Jornadas de Investigación Quinto Encuentro de Investigadores en Psicología del MERCOSUR. Facultad de Psicología-Universidad de Buenos Aires.

Mikulic, I. M., Muiños, R., Cassullo, G. L., Crespi, M. C., Caruso, A. P., Elmasian, M.(2012). Evaluación de la percepción de riesgo en diferentes grupos sociales: propuesta de un modelo de ecuaciones estructurales. *Anu. investig.-Fac. Psicol., Univ. B. Aires*, 19(2), 37-44.

Orlandoni, G. (2007) Indicadores de Riesgo Bancario determinados mediante el Modelado con Ecuaciones Estructurales.

Poza Lara, C., & Fernández Cornejo, J. A. (2011). ¿ Qué factores explican la pobreza multidimensional en España?: una aproximación a través de los modelos de ecuaciones estructurales. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, (12), 81-110.

Rohrman, B. (1994). Risk perception of different societal groups: Australian findings and crossnational comparisons. *Australian Journal of Psychology*, 46(3):150–163.

Rohrman, B. (2002). Risk attitude scales: Concepts and questionnaires. Melbourne: University of Melbourne, p. 12.

Rohrman, B. (2005). Risk attitude scales: concepts, questionnaires, utilizations. Project report. Online access <http://www.rohrmannresearch.net/pdfs/rohrmann-ras-report.pdf>, 13:2012.

Rohrman, B. (2008). Risk Perception, Risk Attitude, Risk Communication. InRisk Management: A Conceptual Appraisal (Keynote). In: 15th International Emergency Management Society (TIEMS) Annual Conference, Prague. http://tiems.info/dmdocuments/events/TIEMS_2008_Bernd_Rohrman_Keynote.pdf.

Schumacker, R. E. y Lomax, R. G. (2010). A Beginner's Guide to Structural Equation Modeling. Routledge.

Segovia-Vargas, M. J., Pascual-Ezama, D., & Rodríguez-Piñero, P. T. (2015). Análisis de los factores de riesgo en el seguro de automóvil mediante ecuaciones estructurales1. *INNOVAR. Revista de Ciencias Administrativas y Sociales*, 25, 121-129.