

LOS MODELOS CAUSALES ASOCIADOS A
ESTRUCTURAS DE COVARIANCIAS: UNA
VÍA PARA LA UNIFICACIÓN DE LOS
"DOS MÉTODOS DE LA PSICOLOGÍA
CIENTÍFICA"

R. LÓPEZ FEAL

Departamento de Psicología Experimental
Universidad de Barcelona

Rafael López Feal
Departamento de Psicología Experimental
Facultad de Filosofía y Ciencias de la Educación
Avda. de Chile, s/n.
Barcelona-28.

1. INTRODUCCIÓN

El problema de la Psicología como ciencia bifurcada se remonta al nacimiento de la psicología como disciplina científica, en la segunda mitad del siglo pasado. Sin embargo, fue Cronbach quien en una publicación aparecida en 1957 formaliza por primera vez las diferencias fundamentales entre las dos corrientes históricas de esta disciplina bifurcada, a las que denomina «Psicología Experimental» y «Psicología Correlacional». Además, en esta publicación Cronbach expone la versión anticipada de las «dos culturas» (Snow, 1959) y plantea, después de más de 50 años, la absoluta necesidad de incorporar en un sistema unificado los paradigmas experimental y correlacional.

Esta propuesta de Cronbach ha sido recogida en una primera etapa convergente por una serie de autores entre los que destacan Cattell (1966) y Eysenck (1967), quienes durante varios años realizan una extensa labor investigadora encaminada a superar la dicotomía que vinculaba el análisis bivariante con la Psicología Experimental y el análisis multivariante con la Psicología de «diferencias individuales».

Otra aportación fundamental a este proceso de unificación está representada por un artículo de Cohen, publicado en 1968, donde propone el modelo lineal de la Regresión Múltiple como sistema general de análisis de datos compartido por la Psicología Experimental y Correlacional. Esta vía de unificación abierta por Cohen es desarrollada ampliamente en años posteriores, a pesar de la resistencia de muchos experimentalistas a abandonar sus métodos tradicionales. En este sentido son de destacar los esfuerzos de Kerlinger y Pedhazur (1973) y Cohen y Cohen (1975) por integrar los diseños ANOVA dentro de la estructura del modelo de la regresión múltiple estándar.

Al margen del escepticismo manifestado por Cronbach en una nueva publicación aparecida en 1975 (Cronbach, 1975), un paso más en este proceso de unificación de la investigación experimental y no experimental lo constituyen los Modelos Causales de ecuaciones estructurales simultáneas asociadas a las estructuras de covariancia.

Por la importancia que están adquiriendo estos modelos interdisciplinarios, surgidos en el contexto de la investigación no experimental, vamos a centrar este artículo en una introducción a dichos modelos.

Para ello, después de una presentación histórica, expondremos el modelo general, que asume una estructura causal entre un conjunto de variables latentes asociadas a modelos de medida. Luego sistematizaremos los procesos fundamen-

tales que deben seguirse para la aplicación de Modelos Causales. Por último, plantharemos algunas reflexiones sobre el alcance y límites de los Modelos Causales en investigación no experimental.

2. ORÍGENES DE LOS MODELOS CAUSALES

Aunque los Modelos Causales, como instrumentos interdisciplinarios, han adquirido su formalización definitiva durante la última década, su gestación ha durado largos años. Podríamos dividir la historia de estos modelos en tres períodos:

1) Antecedentes remotos. — Las aportaciones de esta etapa, que comprende desde principios de siglo hasta la década de los años 50, son muy dispersas. Van desde el análisis factorial hasta las hipótesis causales de los sociólogos, asociadas al teorema de la covariación (Simon, 1954; Blalock, 1961), pasando por la Correlación parcial, el «path Diagram» del genetista Wright (1934) y las ecuaciones estructurales de los econométricos de los años 40.

2) Etapa de formalización y colaboración interdisciplinaria. — Esta etapa comprende la década de los años 60 y culmina en 1973 con motivo de un Seminario interdisciplinario en el que participan expertos en Econometría, Sociología, Estadística y Psicometría. Entre las publicaciones que han contribuido a esta formalización destacamos las de Duncan (1966) Blalock (1969), Jöreskog (1969) y, especialmente, el «reading» publicado por Goldberger y Duncan (1973), que recoge las conclusiones y aportaciones de los distintos participantes en el Seminario anteriormente citado. Por encima de los diversos objetos de estudio de cada disciplina, dichos participantes se han puesto de acuerdo en cuanto a la existencia de tres tipos de características fundamentales comunes, recogidas por Goldberger en la presentación del «reading» anteriormente citado. Éstas son:

- Una primera convergencia está relacionada con el análisis de datos no experimentales. Aquí el problema se centra en la necesidad de elaborar procedimientos de manipulación estadística de los datos ante la imposibilidad de su manipulación metodológica, posible sólo a través del método experimental.
- Una segunda convergencia se relaciona con los constructos hipotéticos asociados a variables latentes que hay que generar a partir de las variables observables.
- Por último, la tercera convergencia está relacionada con los sistemas de ecuaciones estructurales, que actúan simultáneamente, asociados a los modelos causales hipotetizados. Es importante destacar que estos sistemas de ecuaciones matemáticas (lineales, en la mayoría de los casos) se diferencian de otras ecuaciones en el sentido de que no sólo representan una relación matemática sino también una relación teórica causa-efecto, por lo que no tiene significado sustantivo si no existe un soporte teórico que los justifique.

3) Etapa de elaboración de programas de computadora asociadas al Modelo Causal y aplicación de submodelos a distintas disciplinas y diseños dentro de cada disciplina. — Esta etapa se inicia en 1972-1973 con el modelo de JKW (Jöreskog, 1973; Keesling, 1972; Wiley, 1973). Aunque en este modelo participaron principalmente estos tres autores, fue Jöreskog quien ha tenido la mayor aportación y quien lo formaliza a través del conocido programa de computadora LISREL (Lineal Structural RELationships), cuya primera versión comercializada se publica en 1972 (Jöreskog and Van Thillo, 1972). Posteriormente, en 1978, se publica una nueva versión, el LISREL IV (Jöreskog & Sörbom, 1978) y más recientemente ha aparecido la última versión, con el nombre de LISREL V (Jöreskog & Sörbom, 1981) que optimiza las posibilidades de este modelo y amplía su utilización con variables escaladas a nivel ordinal.

Aunque estos modelos han tenido ya amplia aplicación en disciplinas tales como la Sociología, Econometría y, en menor grado, en Psicología (Bentler, 1980), se prevé que en los próximos años adquieran una mayor utilización, tanto en investigación básica como en el campo aplicado, dada su flexibilidad y el grado de formalización que han alcanzado. En este sentido son muchas las publicaciones aparecidas durante los últimos años sobre el tema, tanto a nivel de textos como de artículos. Entre los textos, destacamos las publicadas por Duncan (1975), Heise (1975) y Kenny (1979).

3. MODELOS CAUSALES Y DISEÑOS DE RECOGIDA DE DATOS

Cuando se plantea una investigación, se parte de un diseño de recogida de las observaciones. Tradicionalmente el tipo de diseño de recogida de datos es el que ha determinado el tipo de relaciones de tratamiento matemático estadístico de dichos datos. Como ejemplo de ello tenemos el método de análisis de la variancia y el método correlacional, asociados respectivamente a los diseños experimentales y a los diseños no experimentales. Durante bastantes años se ha considerado que sólo desde los primeros se podían cumplir las condiciones fundamentales para poder establecer relaciones causa-efecto entre las variables (Campbell & Stanley, 1963). Sin embargo, con la aparición de los modelos causales de ecuaciones simultáneas, asociadas a estructuras de covariancia, se ha conseguido especificar, identificar, estimar y probar relaciones causa-efecto entre variables a partir de matrices de covariancia o de correlación. Con ello se ha dado un paso más en el largo proceso de unificación de los modelos generales asociados a tratamiento de datos, sin pérdida de identidad de los respectivos diseños de recogida de datos, que siguen agrupándose en los dos grandes tipos tradicionales: experimentales, en los que hay un riguroso control del orden y sucesión de los hechos, y no experimentales, en los que como máximo se puede llegar a recoger datos paralelos o sucesivos en situaciones estandarizadas, pero no manipuladas.

4. ECUACIONES FUNDAMENTALES ASOCIADAS AL SISTEMA GENERAL DE LOS MODELOS CAUSALES

Antes de exponer los procesos fundamentales asociados tanto a modelos causales recursivos o jerárquicos como a modelos no recursivos o de causación mutua, vamos a presentar las ecuaciones fundamentales del sistema general subyacente al modelo general. Para esta exposición se sigue al modelo asociado al programa LISREL V (Jöreskog and Sörbom, 1981).

Dicho sistema general consta de tres partes:

1) Un modelo de ecuación estructural con la siguiente representación matricial:

$$\underline{\eta} = \underline{\beta}\underline{\eta} + \underline{\Gamma}\underline{\xi} + \underline{\zeta} \quad (1)$$

2) Una ecuación asociada al modelo de medida para las variables endógenas (en terminología no experimental) o dependientes (en terminología experimental). La representación matricial de dicha ecuación es la siguiente:

$$\underline{y} = \underline{\Lambda}_y \underline{\eta} + \underline{\varepsilon} \quad (2)$$

3) Una ecuación asociada al modelo de medida para las variables exógenas (en terminología no experimental) o independientes (en terminología experimental). Esta ecuación tiene la siguiente representación matricial:

$$\underline{x} = \underline{\Lambda}_x \underline{\xi} + \underline{\delta} \quad (3)$$

Donde:

$\underline{\eta}$ (ETA) y $\underline{\xi}$ (KSI) son variables latentes asociadas a las variables observables \underline{y}^s y \underline{x}^s respectivamente.

$\underline{\beta}$ y $\underline{\Gamma}$ son matrices de coeficientes. Las $\underline{\beta}^s$ representan efectos causales directos de las variables $\underline{\eta}$ sobre otras variables $\underline{\eta}$ y los elementos $\underline{\Gamma}$ efectos causales directos de las variables $\underline{\xi}$ sobre las variables $\underline{\eta}$.

$\underline{\zeta} = (\zeta_1, \zeta_2, \dots, \zeta_m)$ es un vector al azar de residuales o de términos de perturbación (variables no controladas).

$\underline{\delta}$ y $\underline{\varepsilon}$ son vectores de errores de medición asociados a las \underline{x}^s e \underline{y}^s , respectivamente.

Las matrices $\underline{\Lambda}_x$ ($p \times m$) y $\underline{\Lambda}_y$ ($q \times n$) son matrices de regresión de \underline{x} sobre $\underline{\xi}$ y de \underline{y} sobre $\underline{\eta}$, respectivamente.

El LISREL V utiliza la siguiente notación matricial para los parámetros estimados:

Λ_y = LAMBDA-Y (Matriz $p \times m$)

Λ_x = LAMBDA-X (Matriz $q \times n$)

B = BETA (Matriz $m \times m$)

Γ = GAMMA (Matriz $m \times n$)

Φ = PHI (Matriz de Covariancias de ξ ($n \times n$))

Ψ = PSI (Matriz de Covariancias de ζ ($m \times m$))

θ_{ϵ} = THETA-EPSILON (Matriz de Covariancias de ϵ)

θ_{δ} = THETA-DELTA (Matriz de Covariancias de δ)

5. PROCESOS FUNDAMENTALES EN LA APLICACIÓN DE MODELOS CAUSALES

Con el fin de mostrar las posibilidades de aplicaciones del modelo general expuesto en el punto anterior, vamos a desarrollar, a través de un ejemplo, los procesos que se siguen para la aplicación de modelos causales, que se corresponden con la estructura general de un sistema científico.

Estos procesos son los siguientes:

1) **ESPECIFICACION** del modelo: del informe verbal a la formalización de la o las hipótesis. En el supuesto de que el modelo sea completo, en esta primera etapa de especificación de un modelo causal deben hipotizarse simultáneamente, por una parte, los modelos de medida subyacentes a las variables exógenas o independientes y a las variables endógenas o dependientes y, por otra, el modelo estructural de relaciones causa-efecto entre las variables latentes generadas por los respectivos modelos de medida.

El modelo hipotetizado se puede formalizar a través de un «Path Diagram» y a través de ecuaciones matriciales.


Vamos a concretar esta importante etapa de **ESPECIFICACION** de un modelo causal a través de un ejemplo derivado del sistema teórico de Fishbein y Ajzen (1975), sobre los factores predictores de la conducta social y su sistema relacional.

En la teoría especificada por estos autores (1975), sobre relaciones actitud-conducta, se hipotetiza que las intenciones de comportarse de una determinada manera con respecto a un objeto o situación pueden ser expresadas a través de una combinación lineal o suma ponderada de las actitudes hacia dicha conducta y las normas subjetivas relacionadas con ella. Las intenciones, a su vez, son consideradas como las determinantes inmediatas de las correspondientes conductas manifiestas.

Utilizaremos este sistema teórico de Fishbein y Ajzen (1975) para exponer el paso del informe verbal a su formalización a través de un «Path Diagram» y de ecuaciones matriciales (1).

1. Un proyecto de investigación, elaborado a partir de la teoría de Fishbein y Ajzen, se expone en el trabajo «Factores predictores de la conducta de asistencia a clase y de rendimiento escolar en estudiantes universitarios», publicado por el Departamento de Psicología Experimental de la Universidad de Barcelona (López Feal, 1982).

a) REPRESENTACION EN "PATH DIAGRAM"



b) REPRESENTACION MATRICIAL

Modelo general de medida para variables exógenas.

$$X = \Lambda_x \eta + \delta$$

Modelo estructural general: Efectos de las variables exógenas sobre las variables endógenas y de las variables endógenas entre sí.

$$\eta = \beta \eta + \Gamma \xi + \zeta$$

Modelo general de medida para variables endógenas.

$$Y = \Lambda_y \eta + \epsilon$$

c) ESPECIFICACION DE ACUERDO CON EL "PATH DIAGRAM"

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \end{pmatrix} = \begin{pmatrix} \lambda_{11} & 0 \\ \lambda_{21} & 0 \\ \lambda_{31} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \\ 0 & \lambda_{62} \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \end{pmatrix}$$

$$\begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} = \begin{pmatrix} 0 & 0 \\ \beta_{21} & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \gamma_{11} \\ \gamma_{12} \end{pmatrix} + \begin{pmatrix} \zeta_1 \\ \zeta_2 \end{pmatrix}$$

$$\Phi = \begin{pmatrix} \Phi_{11} & \Phi_{12} \\ \Phi_{21} & \Phi_{22} \end{pmatrix}$$

$$\begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \\ Y_5 \\ Y_6 \end{pmatrix} = \begin{pmatrix} \lambda_{12} & 0 \\ \lambda_{22} & 0 \\ \lambda_{32} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \\ 0 & \lambda_{62} \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \\ \epsilon_5 \\ \epsilon_6 \end{pmatrix}$$

Figura 1. REPRESENTACION DEL SISTEMA TEORICO DE FISHBEIN Y AJZEN

En la Figura 1 representamos un modelo concreto de análisis multivariado con variables latentes, elaborado a partir de la teoría de Fishbein y Ajzen (1975). Para la formalización de dicho modelo se utiliza simultáneamente su representación en «Path Diagram» y en ecuaciones matriciales.

Como ejemplo del modelo especificado en la Figura 1 podemos citar el expuesto por Bentler y Speckart (1979) en su trabajo «Models of attitude-behavior relations» en el que evalúan varios modelos teóricos alternativos aplicados al consumo de drogas y alcohol. Limitando este ejemplo sólo al consumo de alcohol, las variables expuestas en el modelo de la Figura 1, podrían tener la siguiente representación:

- Las variables empíricas u observables x_1 , x_2 y x_3 representarían indicadores de la *actitud* ante el consumo de alcohol en un contexto individual, de grupo de amigos o de fiesta en un grupo amplio, respectivamente.
- El constructo o variable latente ξ_1 representaría la *estructura latente de la actitud* ante el consumo de alcohol, subyacente a las variables observables x_1 , x_2 y x_3 .
- Las variables empíricas x_4 , x_5 y x_6 representarían indicadores de las normas subjetivas ante la conducta de consumo de alcohol en un contexto individual, de grupo de amigos o de fiesta en un grupo amplio, respectivamente.
- El constructo ξ_2 representaría la *estructura latente de las normas subjetivas* ante el consumo de alcohol, subyacente a las variables observables x_4 , x_5 y x_6 .
- Las variables empíricas y_1 , y_2 e y_3 representarían indicadores de la *intención de comportamiento* ante el consumo de alcohol en un contexto individual, de grupo de amigos o de fiesta en un grupo amplio, respectivamente.
- El constructo η_1 representaría la *estructura latente de intención de comportamiento* ante el consumo de alcohol, subyacente a las variables observables y_1 , y_2 e y_3 .
- Las variables empíricas y_4 , y_5 e y_6 representarían indicadores de *comportamiento o conducta* de consumo de alcohol en un contexto individual, de grupo de amigos o de fiesta en un grupo amplio, respectivamente.
- El constructo η_2 representa la *estructura latente de la conducta* de consumo de alcohol, subyacente a las variables observables y_4 , y_5 e y_6 .

El modelo especificado en la Figura 1 responde a la forma más general de un modelo recursivo asociado a la siguiente matriz SIGMA ($\underline{\Sigma}$) de variancias-covariancias entre todas las variables observables incluidas en dicho modelo:

$$\underline{\Sigma} = \begin{pmatrix} \underline{\Sigma}_{yy} & \underline{\Sigma}_{yx} \\ \underline{\Sigma}_{xy} & \underline{\Sigma}_{xx} \end{pmatrix}$$

En el modelo LISREL los elementos de la matriz $\underline{\Sigma}$ son funciones de los elementos de las matrices de parámetros $\underline{\Lambda}_y$, $\underline{\Lambda}_x$, \underline{B} , $\underline{\Gamma}$, $\underline{\Phi}$, $\underline{\Psi}$, $\underline{\Theta}_\varepsilon$, $\underline{\Theta}_\delta$.

A partir de este modelo general pueden ser especificadas una gran variedad de submodelos como casos especiales. Cada submodelo comprendería sólo algunas de las ocho matrices de parámetros incluidas en el modelo general.

Entre los tipos más comunes de submodelos destacamos los siguientes:

a) Submodelo en el que sólo se opera con las variables observables x y las variables latentes ξ . Este submodelo correspondería a un modelo de medida o modelo de análisis factorial representado a través de la siguiente ecuación:

$$\underline{x} = \underline{\Lambda}_x \underline{\xi} + \underline{\delta}$$

En este caso no hay variables y ni variables η y las únicas matrices de parámetros incluidas en el modelo son $\underline{\Lambda}_x$, $\underline{\Phi}$ y $\underline{\Theta}\underline{\delta}$.

La mayoría de los modelos psicométricos de fiabilidad se resuelven a través de especificaciones desde el contexto de este submodelo.

b) Cuando sólo se opera con las variables observables y y las variables observables x , el programa asume el submodelo:

$$\underline{y} = \underline{B}\underline{y} + \underline{\Gamma}\underline{x} + \underline{\zeta}$$

Este submodelo correspondería a un modelo de ecuación estructural para variables observadas directamente.

Sí, además, $\underline{B} = \underline{O}$ se pueden especificar modelos de regresión multivariantes y otras formas del modelo lineal general.

En este caso no hay variables latentes ξ y η , estando incluidas en el modelo sólo las matrices de parámetros \underline{B} , $\underline{\Gamma}$ y $\underline{\Psi}$.

La mayoría de los diseños experimentales en los que se opera con variables empíricas podrían especificarse en el contexto de este submodelo.

c) Por último, en aquellos casos en los que sólo se especifican las variables observables y y las variables latentes η y ξ , el submodelo asumido por el programa tiene la siguiente representación:

$$\begin{aligned} \underline{\eta} &= \underline{B}\underline{\eta} + \underline{\Gamma}\underline{\xi} + \underline{\zeta} \\ \underline{y} &= \underline{\Lambda}_y \underline{\eta} + \underline{\varepsilon} \end{aligned}$$

Cuando $\underline{B} = \underline{O}$, este submodelo se transforma en un modelo de análisis factorial de segundo orden con cargas factoriales de primer orden dadas por la matriz $\underline{\Lambda}_y$ y cargas factoriales de segundo orden dadas por la matriz $\underline{\Gamma}$. Este modelo de análisis factorial tendría la siguiente representación:

$$\underline{y} = \underline{\Lambda}_y (\underline{\Gamma}\underline{\xi} + \underline{\zeta}) + \underline{\varepsilon}$$

Aunque hay otros submodelos que podrían especificarse a partir del modelo general, consideramos que todos ellos son casos especiales de algunos de estos tres tipos que acabamos de exponer.

Antes de concluir esta introducción al proceso de especificación de un Modelo Causal, queremos resaltar que son múltiples las posibilidades de aplicación interdisciplinaria que tiene este modelo general. También queremos destacar que son muchos los problemas substantivos y metodológicos que plantea su aplicación en cada caso. En concreto, los problemas de escalamiento de las variables así como los de su validez y fiabilidad son todavía un reto que tiene planteado fundamentalmente la Psicometría.

2) IDENTIFICACION del modelo asociado a la hipótesis causal especificada.

Una vez especificado un modelo, se pasa a la etapa de identificación, que consiste en comprobar si el modelo hipotetizado permite representar los datos. La condición necesaria, aunque no siempre suficiente, para la identificación de modelos de ecuaciones estructurales es que los grados de libertad del modelo deben ser igual o mayor que cero ($df \geq 0$). Si $df = 0$, hay una solución única para los parámetros y el modelo no puede ser probado, porque está exactamente identificado. Por el contrario, si $df > 0$ el modelo puede ser probado.

Los problemas que plantea la identificación de un modelo son distintos en los modelos recursivos y no recursivos.

Los primeros son siempre identificados, mientras que la identificación de los no recursivos suele ser más complicada.

Teniendo en cuenta el carácter introductorio de este punto, no vamos a entrar en detalles con respecto a estos problemas, y centraremos esta exposición en la identificación de modelos recursivos, utilizando, para ello, como ejemplo el modelo causal especificado en la etapa anterior.

Como ya se ha anticipado, el problema de la identificación se centra en la obtención de la diferencia entre los parámetros asociados a la matriz de covariancias o de correlaciones de población (Matriz Σ ó Σ^*) (2) y el número de parámetros estructurales asociados al modelo hipotetizado.

El número de parámetros asociados a la matriz SIGMA se obtiene a través de la siguiente ecuación:

$$N.^{\circ} \text{ de parámetros SIGMA} = 1/2 n (n + 1),$$

donde n es el número de variables empíricas de la matriz $n \times n$ de covariancias o de correlaciones.

El número de parámetros asociados al modelo estructural es igual al número de $\Phi_{ij}^s + \Phi_{ij}^s + \Upsilon_{ij}^s + \beta_{ij}^s + \Psi_{ii}^s + \Psi_{ij}^s$.

2. La matriz SIGMA se obtiene a partir de la matriz de covariancias o de correlaciones (Matriz S o S^*) de muestra. Esta matriz se reduce a la obtención de la covariancia o de la correlación entre todas las variables observadas. Por ello algunos autores denominan a los modelos causales «Modelos de estructura de covariancia».

Las Φ^s se obtienen a través de la misma fórmula utilizada para hallar los parámetros de la matriz Σ ; es decir:

$$N.^{\circ} \text{ de parámetros } \Phi^s = 1/2 q (q + 1),$$

donde q es el número de variables ξ^s o de variables x^s , en el caso de que el modelo causal opere directamente con variables empíricas.

En el ejemplo especificado en la Figura 1, hay dos grados de libertad ($df = 2$), teniendo en cuenta que tenemos 10 ecuaciones asociadas a la matriz SIGMA y 8 ecuaciones asociadas al modelo causal hipotetizado. En consecuencia, el modelo cumple la condición necesaria para ser identificado.

3) ESTIMACION de parámetros del modelo causal identificado.

Después de que el modelo haya sido identificado, se pasa a la etapa de estimación de parámetros. Para ello se parte de la matriz de covariancias (Matriz S) o bien de la matriz de correlaciones (Matriz S^*) entre los datos de muestra. A partir de esta matriz se obtiene la matriz Σ ó Σ^* , que representan las covariancias o correlaciones de población, respectivamente.

Aunque no vamos a entrar aquí en una exposición detallada de los procesos y alternativas para la estimación de parámetros del modelo, sí queremos plantear algunas observaciones acerca de esta importante etapa de estimación. Éstas son:

- a) Los parámetros del modelo pueden ser estimados a partir de la matriz de covariancias o de correlaciones de muestra. Sin embargo, al no ser idéntica esta matriz a su correspondiente matriz de población (3), para estimar los valores de los parámetros del modelo hay que estimar previamente las diferencias entre estadísticos de la muestra (Matriz S ó S^*) y los parámetros de población (Matriz Σ ó Σ^*). Esta estimación reflejará la discrepancia entre las covariancias de población y las covariancias de muestra y se representa a través de la matriz de residuales. Si el modelo hipotetizado es correcto, los residuales tienen que ser muy próximos a cero. Por el contrario, si es incorrecto, estos residuales suelen estar alejados de cero y pueden utilizarse como un indicador de que el modelo hipotetizado es incorrecto.
- b) Los métodos más empleados para la estimación de los parámetros en modelos causales son el método de mínimos cuadrados no ponderados (ULS), el método de mínimos cuadrados generalizados o ponderados (GLS) y el método de máxima verosimilitud (ML). Aunque el más utilizado en los últimos años es el de máxima verosimilitud, cada uno de ellos tiene sus ventajas e inconvenientes en cada caso. No vamos a entrar aquí en esta discusión y

3. Las matrices de covariancia de muestra y población sólo son idénticas en el caso de que los grados de libertad del modelo sean igual a cero ($df=0$).

remitimos al texto de Saris y Stronkhorst (1981, Volumen 1), para una breve introducción a estos métodos de estimación.

4) Etapa de prueba de AJUSTE del modelo.

Las pruebas de ajuste tienen como finalidad comprobar en qué grado los modelos causales hipotetizados se ajustan a los datos. Estos datos pueden ser de dos tipos:

- a) Datos representados por la matriz de covariancias o de correlaciones entre las variables empíricas, en cuyo caso no existe un modelo de medida.
- b) Datos representados por la matriz de covariancias o de correlaciones entre variables latentes generadas a partir de los datos empíricos. En este caso los datos estarían representados a través de modelos de medida.

Sin embargo, la existencia o no de modelos de medida asociados a los datos, aunque tiene repercusiones substantivas, no afecta al tipo de prueba de ajuste, que en ambos casos suele ser la prueba de bondad de ajuste estadística Chi-Cuadrado.

Como criterio general para la interpretación de la bondad de ajuste se parte del hecho de que en los modelos recursivos saturados ($df = 0$) el ajuste entre el modelo y los datos es perfecto. Así, cuando hipotetizamos modelos no saturados, es decir, con grados de libertad mayores que cero ($df > 0$), la prueba de Chi-Cuadrado (χ^2) nos permite obtener un indicador del grado de ajuste entre el conjunto de parámetros del modelo y los datos. En consecuencia, la prueba de Chi-Cuadrado es una función directa de la discrepancia entre la matriz de covariancias o de correlaciones de muestra y la matriz reproducida por los parámetros estimados del modelo hipotetizado.

La prueba de ajuste χ^2 se puede utilizar también para contrastar modelos alternativos con el fin de encontrar el modelo óptimo. En este caso, el número de grados de libertad viene determinado por la diferencia entre los grados de libertad de los modelos enfrentados.

Esta segunda opción, aunque ha sido muy utilizada en los últimos años, sólo se justifica en el caso de que los modelos alternativos al que ha sido especificado puedan justificarse teóricamente.

5) Etapa de INTERPRETACION de parámetros estimados y de residuales.

Para la interpretación de los parámetros efecto (γ^s y β^s) y de los términos de perturbación (variancias no explicadas, ψ^s) no sólo hay que tener en cuenta el peso de los coeficientes obtenidos sino también el error estándar y la significación estadística de este error estándar, que se obtiene a través de una prueba t de ajuste. Si el error estándar no es estadísticamente significativo a un nivel de confianza determinado (5 % generalmente) podemos afirmar que la relación causal hipotetizada o procedente de los términos de perturbación es correcta.

Otra información importante que debe tenerse en cuenta en esta etapa de interpretación estadística es la aportada por la matriz de residuales representada por la discrepancia entre los valores ij de la matriz de covariancias o correlaciones de muestra (Matriz S ó S^*) y la matriz de covariancias o correlaciones de población (matriz Σ ó Σ^*).

Por último, para esta etapa de interpretación de los parámetros estimados, también pueden aportar información las matrices derivadas de primer orden. Estas matrices nos permiten comprobar si los parámetros efecto que hemos fijado con valor cero tienen realmente dicho valor y, en consecuencia, nos dan pautas para modificar el modelo, si este es el caso.

Antes de terminar esta breve exposición sobre la importante etapa de interpretación de parámetros, queremos plantear aquí las mismas observaciones que en el caso de contraste entre modelos alternativos. Es decir, consideramos que ninguna corrección del modelo hipotetizado debe hacerse de una manera automática, siguiendo sólo criterios estadísticos, y, por consiguiente, deben utilizarse fundamentalmente criterios teóricos como guía para las correcciones de modelos inicialmente planteados.

No queremos concluir esta breve exposición de los procesos fundamentales en la aplicación de los modelos causales sin antes destacar que la pretensión de este artículo se limita a una introducción en lengua castellana al tema de los **MODELOS CAUSALES** y, en consecuencia, la utilización, deseada, de estos modelos en Psicología, requiere un conocimiento instrumental del Programa de Computadora utilizado y unas bases de Estadística y de Álgebra Matricial, además de un conocimiento substantivo del campo al que se aplican, todo lo cual sobrepasa los límites de esta publicación.

6. ALCANCE Y LÍMITES DE LOS MODELOS CAUSALES EN INVESTIGACIÓN NO EXPERIMENTAL

Podemos afirmar que la mayor aportación de los Modelos Causales a la investigación no experimental ha sido la de haber elaborado instrumentos formalizados que permiten el paso de las relaciones de covariancia o correlación entre variables a relaciones causa-efecto. Este importante paso, como señala Kenny (1979), «puede ayudarnos a comprender las causas de nuestra conducta diaria donde no es posible crear una situación de laboratorio».

Sin embargo, aún reconociendo esta gran aportación de los Modelos Causales a la investigación no experimental, estos modelos tienen una serie de limitaciones entre las que destacamos las siguientes:

1. Debe haber un soporte teórico que justifique el paso de relaciones de covariancia a relaciones causa-efecto y este soporte no siempre existe en muchos de los campos de la Psicología, sobre todo en los asociados a la investigación no experimental, donde las hipótesis causales no se apoyan muchas veces en leyes causales sino más bien en imágenes y especulaciones.

2. Los datos objetos de investigación deben estar apoyados por una cuidadosa metodología de observación y esto no es posible en muchos casos fuera de la investigación experimental de laboratorio.

Como consecuencia de estas limitaciones, al utilizar el modelo causal en investigación no experimental debe evitarse caer, por una parte, en especulaciones causales a partir de las simples observaciones y, por otra, en el reduccionismo estadístico, haciendo interpretaciones a partir de los simples datos aportados por la computadora.

En síntesis, los modelos causales, como cualquier otro modelo, no tienen sentido si no están integrados en un sistema armonioso de interrelación entre teoría, método y tratamiento de datos. Entendido de esta manera, el modelo causal no es un instrumento mágico, sino que su función se centra en enfrentarse con supuestos teóricos, en clasificar cuestiones metodológicas y estadísticas y en servir de criterio de referencia en la búsqueda de explicaciones científicas a los fenómenos objeto de investigación.

RESUMEN

A través de este artículo he pretendido exponer una introducción a los Modelos Causales desde las perspectivas histórica, metodológica y estadístico-matemática.

Asimismo, he planteado las posibilidades que tienen estos modelos, asociados a estructuras de covariancia, como vía que puede contribuir a superar la dicotomía método experimental/método correlacional.

Para la exposición de los procesos de especificación, identificación, estimación, prueba de ajuste e interpretación de parámetros de un modelo causal he tomado como referencia el modelo LISREL. Sin embargo, en la sistematización de estos procesos no he intentado presentar solamente la simple descripción del modelo, insistiendo, para ello, en la necesidad de integrar este modelo en el contexto del método científico.

SUMMARY

Across this article I had pretended to expose an introduction at the causal models from the historical, methodological and estatistic-mathematic perspectives.

Likewise, I had planed the possibilities that have these models, associates to covariance structures, as a way that can contribute to overcome the dichotomy experimental method/correlational method.

I had taken as reference the LISREL model for the exposition of the processes of specification, identification, estimate, testing and interpretation of parameters of a causal model. However, in the systematization of these processes I have not intended to present only the simple description of the model, insisting for it in the necessity of integrate this model in the context of the scientific method.

BIBLIOGRAFÍA

- BENTLER, P. M. Multivariate analysis with latent variables: Causal Modeling. *Annual Review of Psychology*, 1980, 31, 419-456.
- BENTLER, P. M. & SPEKART, G. Models of attitude-behaviors relations. *Psychological Review*, 1979, 85, 452-464.
- BLALOCK, H. M. Correlation and Causality: The Multivariate case. *Social Forces*, 1961, 39, 246-251.
- BLALOCK, H. M. *Theory Construction. From Verbal to Mathematical Formulation*. Englewood Cliff, New Jersey: Prentice-Hall, 1969.
- CAMPBELL, D. T. & STANLEY, J. C. *Experimental and quasiexperimental designs for research*. Chicago, Illinois: Rand McNally, 1966. (Hay traducción castellana en Amorrortu Editores, Buenos Aires, 1973.)
- CATTELL, R. B. Multivariate behavioral research and the integrative challenge. *Multivariate Behavioral Research*, 1966, 1, 4-23.
- COHEN, J. Multiple Regression as a general data: Analytic System. *Psychological Bulletin*, 1968, 70, 426-443.
- COHEN, J. & COHEN, P. *Applied Multiple Regression-Correlation Analysis for the Behavioral Sciences*. Hillsdale, New Jersey: Lawrence Erlbaum Associates, 1975.
- CRONBACH, L. J. The two disciplines of scientific Psychology. *American Psychologist*, 1957, 12, 671-684. (Hay traducción castellana en F. Alvira y otros (Eds). Los dos métodos de las Ciencias Sociales. Madrid: Centro de Investigaciones Sociales, 1979, págs. 93-124.)
- CRONBACH, L. J. Beyond the two disciplines of scientific Psychology. *American Psychologist*, 1975, 30, 116-127. (Hay traducción castellana en la publicación de la cita anterior, págs. 253-276.)
- DUNCAN, O. D. Path Analysis: Sociological examples. *American Journal of Sociology*, 1966, 72, 1-16.
- DUNCAN, O. D. *Introduction to Structural Equation Models*. New York: Academic Press, 1975.
- EYSENCK, M. J. *The Biological bases of Personality*. Springfield, Illinois: C. C. Thomas Publisher, 1967.
- FISHBEIN, M. & AJZEN, I. *Belief, attitudes, intention and behavior: An introduction to theory and research*. Reading, Massachusetts; Addison-Wesley, 1975.
- GOLDBERGER, A. S. & DUNCAN, O. D. (Eds). *Structural Equation Models in the Social Sciences*. New York: Academic Press, 1973.
- HEISE, D. R.: *Causal Analysis*. New York: John Wiley and Sons, 1975.
- JÖRESKOG, K. G. A general approach to confirmatory maximum likelihood factor analysis. *Psychometrika*, 1969, 34, 183-202.
- JÖRESKOG, K. G. «A general method for estimating a linear structural equation system». In A. S. Goldberger and O. D. Duncan (Eds). *Structural Equation Models in the Social Sciences*. New York: Academic Press, 1973, págs. 85-112.
- JÖRESKOG, K. G. & SÖRBOM, D. *LISREL IV User's Guide*. Chicago, Illinois: National Educational Resources, 1978.
- JÖRESKOG, K. G. & SÖRBOM, D. *LISREL V. Analysis of Linear Structural Relationships by maximum likelihood and least square methods*. University of Uppsala, Sweden, 1981.
- JÖRESKOG, K. G. & VAN THILLO, M. *LISREL: A general computer program for estimating a linear structural equation system involving multiple indicators of unmeasured variables*. Princeton, New Jersey: Educational Testing Services, 1972.
- KEESLING, W. *Maximum likelihood approaches to causal flow analysis*. Ph. D. Thesis. University of Chicago. Chicago, Illinois, 1972.
- KENNY, D. A. *Correlation and Causality*. New York: John Wiley and Sons, 1979.
- KERLINGER, F. N. & PERDHAZUR, R. R. *Multiple Regression in Behavioral Research*. New York: Holt, Rinehart & Winston, 1973.
- LORD, F. M. & NOVICK, M. R. *Statistical Theories of Mental Tests Scores*. Reading, Massachusetts: Addison-Wesley, 1968.

- LÓPEZ FEAL, R. *Factores predictores de la conducta de asistencia a clase y de rendimiento escolar en estudiantes universitarios*. Departamento de Psicología Experimental. Universidad de Barcelona, 1982.
- SARIS, W. E. & STRONKHORST, L. H. *Linear Structural Relationships. Introduction to causal models in nonexperimental research*. Amsterdam: Free University, 1981, Volume 1.
- SIMON, H. A. Spurious Correlation: A Causal interpretation. *Journal of American Statistical Association*, 1954, 49, 467-479.
- SNOW, C. P. *Two cultures and the scientific revolution*. Cambridge: Cambridge University Press, 1959.
- WILEY, D. E. «The identification problem for structural equation models with unmeasured variables». In A. S. Goldberger & O. D. Duncan (Eds). *Structural Equation Models in the Social Sciences*. New York: Academic Press, 1973, págs. 69-83.
- WRIGHT, S. The method of path coefficients. *Ann. Math. Statistics*, 1934, 5, 161-215.