



MÁSTER EN TÉCNICAS ESTADÍSTICAS  
FACULTAD DE MATEMÁTICAS

**ANÁLISIS CAUSAL CON ECUACIONES  
ESTRUCTURALES DE LA SATISFACCIÓN  
CIUDADANA CON LOS SERVICIOS  
MUNICIPALES**

PROYECTO FIN DE MÁSTER

AUTORA: MARÍA ÁNGELES GARCÍA VEIGA

Santiago de Compostela, Julio 2011



Los Profesores César Andrés Sánchez Sello y Manuel Febrero Bande, autorizan la presentación del presente Proyecto Fin de Máster titulado "Análisis Causal con Ecuaciones Estructurales de la Satisfacción Ciudadana con los Servicios Municipales", realizado por la alumna María Ángeles García Veiga y del cual han sido directores.

Santiago de Compostela, Julio de 2011.

César Andrés Sánchez Sello

Manuel Febrero Bande



## ÍNDICE

Introducción.....	1
<b>I. La satisfacción como instrumento de evaluación de los servicios públicos.....</b>	<b>5</b>
<b>II. Revisión metodológica de los Modelos de Ecuaciones Estructurales (SEM).....</b>	<b>9</b>
1. Elementos de un modelo de ecuaciones estructurales.....	14
1.1. Tipos de variables en los modelos de ecuaciones estructurales.....	15
1.2. Los diagramas estructurales. "Path-diagrams" .....	16
1.3. Relaciones entre variables.....	20
2. Construcción del modelo estructural.....	26
2.1. Fase de especificación .....	28
2.2. Fase de estimación.....	30
2.2.1. Estimación por Máxima Verosimilitud.....	31
2.2.2. Estimación por Mínimos Cuadrados Ponderados.....	32
2.2.3. Estimación por Mínimos Cuadrados Generalizados.....	34
2.3. Fase de identificación.....	35
2.4. Fase de evaluación e interpretación.....	35
3. Bondad de ajuste del modelo.....	36
3.1. Ajuste del modelo de medida.....	37
3.2. Ajuste del modelo estructural.....	41
3.3. Medidas de ajuste global.....	42
3.3.1. Medidas absolutas de ajuste.....	42
3.3.2. Medidas incrementales de ajuste.....	46
3.3.3. Medidas de ajuste de parsimonia.....	47

<b>III. Modelización de la satisfacción ciudadana mediante modelos de ecuaciones estructurales. Presentación e interpretación de los resultados.....</b>	<b>51</b>
1. Muestra. Descripción y análisis de la base de datos.....	51
2. Fiabilidad de las escalas. Alpha de Cronbach.....	62
3. Modelo inicial.....	64
4. Identificación del modelo.....	69
5. Estimación y ajuste. Presentación de resultados.....	69
6. Corrección y mejora del modelo.....	87
7. “Modification Indices” (MI) con AMOS.....	98
<b>Conclusiones y futuras líneas de investigación.....</b>	<b>104</b>
<b>Bibliografía.....</b>	<b>109</b>
<b>Anexo.....</b>	<b>113</b>
Índice de figuras	
Figura 1.....	18
Figura 2.....	20
Índice de gráficos	
Gráfico 1.....	22
Gráfico 2.....	24
Gráfico 3.....	39
Gráfico 4.....	61
Gráfico 5.....	65
Gráfico 6.....	71
Gráfico 7.....	84

---

Gráfico 8.....	85
Gráfico 9.....	88
Gráfico 10.....	99

Índice de tablas

Tabla 1.....	49
Tabla 2.....	55
Tabla 3.....	56
Tabla 4.....	59
Tabla 5.....	63
Tabla 6.....	64
Tabla 7.....	72
Tabla 8.....	74
Tabla 9.....	75
Tabla 10.....	76
Tabla 11.....	77
Tabla 12.....	79
Tabla 13.....	80
Tabla 14.....	81
Tabla 15.....	82
Tabla 17.....	83
Tabla 18.....	83
Tabla 19.....	89
Tabla 20.....	90
Tabla 21.....	92
Tabla 22.....	92
Tabla 23.....	93
Tabla 24.....	94
Tabla 25.....	94
Tabla 26.....	95

Tabla 27.....	100
Tabla 28.....	101
Tabla 29.....	101
Tabla 30.....	101
Tabla 31.....	102
Tabla 32.....	102
Tabla 33.....	102
Tabla 34.....	103



## Introducción

La orientación hacia el mercado de las políticas y las exigencias de buen gobierno por parte de la ciudadanía han provocado un giro en el papel de los gobiernos en aras de promover la satisfacción de los consumidores (Osborne y Gaebler, 1992).

Durante los últimos años impera en el sector público la filosofía basada en la Nueva Gestión Pública, que ha generado un cambio de actitud y de comportamiento entre las instituciones públicas provocados por la convergencia y la presión de dos elementos esenciales: por un lado, la demanda de mayores niveles de responsabilidad de las instituciones, presionadas por factores políticos, mediáticos y por la propia ciudadanía, y por otro lado, el compromiso cada vez mayor que los líderes adquieren hacia la consecución de mejores resultados.

Una filosofía que también tendrá consecuencias a nivel municipal, guiando “a las autoridades locales...a acercarse al desafío de desarrollar nuevos patrones de organización más sensibles. Se basa en la idea de que las autoridades locales deberán prestar servicio para y con la gente, y no simplemente hacia la gente” (Walsh, 1989: 6).

De este modo, cuestiones propias del mundo empresarial y el sector privado, como son la Gestión de Calidad Total, el desarrollo del Cuadro de Mando Integral o la aplicación medidas de mejora continua centradas en la satisfacción de las necesidades de los clientes, han tenido un fuerte impacto en este cambio de orientación de la actuación de las administraciones públicas.

Desde esta perspectiva, el éxito de las entidades públicas se ha medido en función de los niveles de satisfacción de los ciudadanos, lo cual ha traído consigo una importante transformación: se pasa de la concepción de usuarios/consumidores de los servicios públicos a ciudadanos.

A todo ello hay que añadir la influencia tan determinante que ha tenido el surgimiento de una sociedad de consumo post-industrial, en la que los consumidores tienen a su alcance un amplio abanico de servicios y productos creados para satisfacer sus necesidades, por muy diversas que éstas fueren. En este sentido, los ciudadanos exigirán a las administraciones públicas servicios con altos niveles de calidad que respondan a sus expectativas de la misma forma que lo hace el mercado.

En resumen, tanto gobiernos como gestores están dando cada vez mayor importancia a la visión de los ciudadanos, prestando mayor atención al papel que la participación ciudadana tiene en la provisión eficiente de los servicios que les proporcionan. En consecuencia, las percepciones de los ciudadanos importan y mucho, pero para conocer su grado de satisfacción es necesario evaluar. De este modo, el estudio de las percepciones de los ciudadanos permitirá identificar los elementos que tienen mayor impacto en su satisfacción, lo cual, a su vez, será de gran ayuda para gestores y líderes en el proceso de toma de decisiones.

Al mismo tiempo, la identificación de los factores o elementos "críticos" con mayor impacto en la satisfacción lleva a introducir mecanismos de mejora que incrementarán la calidad de los servicios. En definitiva, el análisis de la satisfacción de los ciudadanos tiene un papel esencial para el diseño y mejora de los propios servicios; un mecanismo de *feedback* en el que la evaluación conducirá a focalizar los elementos con mayor impacto en la satisfacción, la mejora de estos elementos conduce a ciudadanos más satisfechos, al tiempo que alcanzar mayores niveles de satisfacción es un incentivo para introducir criterios de calidad en los servicios.

---

Esta es la idea con la que nace este Proyecto Fin de Máster: evaluar y medir la satisfacción ciudadana con los servicios municipales (tanto de titularidad pública como privada) a través de los elementos internos de cada servicio, determinando empíricamente las relaciones causales entre los determinantes de la satisfacción. De esta forma se pondrá el foco sobre aquéllos que ejercen un mayor impacto sobre las percepciones de los ciudadanos, con la consecuente utilidad que esto supone desde el punto de vista de la gestión y de la toma racional y económica de decisiones para los líderes de las administraciones locales.

De esta perspectiva, la hipótesis principal que encauza el propósito de este trabajo se centra en determinar si existen diferencias en el nivel de impacto de los elementos internos a cada servicio municipal en la satisfacción de los ciudadanos, para lo cual se propone la aplicación de un modelo de ecuaciones estructurales mediante el cual se analizarán las relaciones causales que surgen entre las variables.

En este Proyecto Fin de Máster se presentan los principios y conceptos básicos que definen este tipo de modelos, incluyendo además su aplicación práctica utilizando una encuesta de satisfacción ciudadana (n=247) con algunos de los servicios públicos prestados en el municipio.

El trabajo ha sido estructurado del siguiente modo: en el Capítulo I se hace una breve introducción al concepto de satisfacción, en el Capítulo 2 se realiza una revisión teórica y metodológica de los modelos de ecuaciones estructurales, describiendo tanto los elementos que los integran como las relaciones causales que surgen entre las variables. Se detallan, además, los principales métodos de estimación y los criterios a tener en cuenta para determinar la bondad de ajuste de un modelo. El Capítulo III contiene la aplicación práctica de modelos de ecuaciones estructurales al estudio de la satisfacción ciudadana.

En resumen, este proyecto ofrece una revisión de los principios y conceptos básicos que definen este tipo de modelos, aplicándolos a una base de datos reales sacados de una encuesta de satisfacción ciudadana con algunos de los servicios públicos prestados en el municipio.

Los modelos de ecuaciones estructurales pueden implementarse en varios paquetes estadísticos. Entre ellos destacan AMOS (Analysis of Moment Structures), como un módulo dentro del programa SPSS; LISREL (Linear Structural Relationships), programa más conocido para el análisis de modelos de ecuaciones estructurales desarrollado por Jöreskog y Sörbom; EQS, que incorpora numerosas aplicaciones relacionadas con los SEM; y R que cuenta con librerías específicas para los SEM.

Para la estimación y representación de los modelos propuestos en este Proyecto fin de Máster se ha empleado el paquete estadístico AMOS en su versión 18.0.

## **CAPÍTULO I**

### **La satisfacción como instrumento de evaluación de los servicios públicos**

El desarrollo de investigaciones empíricas basadas en el estudio de la satisfacción ha provocado que durante los últimos tiempos la literatura se haya centrado en buscar los elementos que más impactan en la satisfacción (e insatisfacción). El objetivo principal de estas investigaciones se centra en conocer cuáles eran los pesos específicos de estos elementos en la construcción global de la satisfacción, para lo cual se apoyan en técnicas estadísticas complejas que ayudan a explicar las relaciones causales que se establecen entre variables.

Entre los componentes de la satisfacción destacan cuestiones como las expectativas, la performance o rendimiento, la desconfirmación, o los afectos, e incluso, medidas específicas directas del nivel de satisfacción que experimenta el consumidor. Es por ello que en los intentos de medición del impacto que cada uno de ellos tiene en el resultado final, han sido muchas y muy variadas las escalas empleadas en las investigaciones empíricas desarrolladas hasta el momento. Con ello, es habitual encontrar en los estudios más recientes el uso de escalas multi-ítem para la evaluación de niveles de satisfacción (Parasuraman et al., 1994a); escalas que fundamentalmente se recogen a través de la realización de encuestas de satisfacción ciudadana.

Para el ámbito local, la relevancia de las encuestas de satisfacción sobre los servicios públicos en la esfera internacional resulta evidente a la vista de los numerosos trabajos realizados en Reino Unido. Junto a otras técnicas, como los paneles de ciudadanos y los *focus group* (entendidos como medios de participación pública), han servido a las autoridades locales como mecanismo para la toma de decisiones, así como instrumento para escuchar y aprender de las necesidades de los ciudadanos.

Pero, ¿por qué utilizar encuestas de satisfacción?. Miller y Miller enumeran 6 razones por las que entidades y organizaciones hacen uso de este tipo de encuestas:

- evaluar las necesidades de la comunidad
- planificar a largo plazo
- planificar a corto plazo
- evaluar la comunicación con los ciudadanos
- evaluar los servicios comunitarios
- determinar una política de seguimiento.

Parece quedar claro que medir la satisfacción con los servicios a través de la opinión de los ciudadanos justifica la creciente tendencia hacia el empleo de encuestas y sondeos de opinión para conocer la valoración subjetiva que de ellos hacen los propios ciudadanos; además de ayudar a discernir entre debilidades y focos susceptibles de mejora en la prestación de los mismos.

La posible institucionalización de estos mecanismos de voz que permitan a los ciudadanos hacer llegar sus valoraciones sobre los servicios prestados tendría, a priori, una importante consecuencia para toda la ciudadanía, puesto que en aquellas organizaciones donde los ciudadanos están activamente representados son más eficientes y proveen servicios de mejor calidad.

En definitiva, la creciente importancia que poco a poco ha adquirido la satisfacción de los ciudadanos y la opinión pública tanto en la aceptación de acciones políticas como de la gestión de los responsables públicos, hace posible que la voz de los ciudadanos se convierta en un mecanismo capaz de transformar los servicios públicos.





## CAPÍTULO II

### Revisión metodológica de los modelos de ecuaciones estructurales (SEM)

El concepto de modelos o sistema de ecuaciones estructurales<sup>1</sup> (SEM) se introdujo hace 80 años por Wrigth (1921, 1934). Trabajando sobre patrones de covariación entre varias características de cobayas, desarrolló una forma de romper las correlaciones observadas en un sistema de ecuaciones que matemáticamente describían su hipótesis respecto a las relaciones causales. Las relaciones entre variables fueron representadas en un "path diagram", por lo que su método llegó a conocerse como "path analysis" (Wright 1921, 1934).

Años más tarde, este método fue redescubierto y desarrollado por economistas y sociólogos, de entre los cuales, los trabajos más sobresalientes son los de Jöreskog (1973, 1977 y 1981) y Jöreskog y Sörbom (1982). En ellos, transformaron el "path analysis" de Wright en un nuevo método denominado "structural equation modelling", en el que se combina el análisis factorial con el path analysis.

En resumen, los modelos de ecuaciones estructurales estudian las relaciones causales entre datos directamente observables, asumiendo la existencia de relaciones lineales, aunque también se pueden modelizar relaciones no lineales. ¿Pero a qué nos referimos con "relación causal"?

---

<sup>1</sup> El nombre que reciben "modelos de ecuaciones estructurales" se debe a que es necesario utilizar un conjunto de ecuaciones para representar las relaciones propuestas inicialmente por el investigador o la teoría.

---

Aunque la existencia de correlación entre dos variables no implica, necesariamente, la existencia de una relación causal entre ambas, la existencia de relación causal entre dos variables sí implica la existencia de correlación. Ésta es en esencia la base de los modelos de ecuaciones estructurales. La modelización de ecuaciones estructurales asume que hay un mecanismo subyacente que lleva a una estructura de covarianzas teóricas entre un vector de variables aleatorias. El objetivo es presentar y testar un modelo que capture la esencia de este mecanismo subyacente.

Las relaciones causales establecidas en la hipótesis de partida implican una serie de limitaciones en la matriz de varianzas-covarianzas. Si la matriz de varianzas-covarianzas que producen los datos observados es compatible con las limitaciones impuestas por la hipótesis, el modelo no se descarta.

La gran ventaja de este tipo de modelos es que permiten proponer el tipo y dirección de las relaciones que se espera encontrar entre las diversas variables contenidas en él, para pasar posteriormente a estimar los parámetros que vienen especificados por las relaciones propuestas a nivel teórico. Por este motivo se denominan también modelos confirmatorios, ya que el interés fundamental es “confirmar” mediante el análisis de la muestra las relaciones propuestas a partir de la teoría explicativa que se haya decidido utilizar como referencia.

Además, con estos modelos, y dada la interdependencia de las variables, es posible descomponer los efectos directos totales en directos e indirectos y testar la bondad de ajuste del modelo como un todo. Además, son de gran utilidad en la comparación de modelos alternativos (competidores), pues permite el uso de variables latentes y la consideración del error de medida que, con la variación de los valores de los índices de bondad de ajuste pueden indicar la existencia de modelos alternativos mejorados.

En definitiva, podemos decir que los puntos fuertes de estos modelos son: haber desarrollado unas convenciones que permiten su representación gráfica, la posibilidad de analizar efectos causales<sup>2</sup> entre las variables, permitir la concatenación de efectos entre variables y permitir relaciones recíprocas entre ellas.

Encuadrados dentro del análisis estadístico multivariante, estos modelos surgieron ante la necesidad de dotar de mayor flexibilidad a los modelos de regresión. Son menos restrictivos que los modelos de regresión por el hecho de permitir incluir errores de medida tanto en las variables criterio (dependientes) como en las variables predictoras (independientes). Podría pensarse en ellos como varios modelos de análisis factorial que permiten efectos directos e indirectos entre los factores.

Más concretamente, algunos de los modelos que se pueden encuadrar dentro de la metodología de los modelos estructurales son: regresión lineal múltiple, análisis factorial confirmatorio, modelo causal con variables latentes, modelos multinivel, modelos basados en las medias (ANOVA, ANCOVA, MANOVA, MANCOVA), y otros; muchos de los cuales serán aplicados en este trabajo de investigación.

En la actualidad, programas de estimación en entorno gráfico, como LISREL (Linear Structural Relations; Jöreskog, 1973) o AMOS (Analysis of Moment Structures, Arbuckle, 1994), han jugado un importante papel en el desarrollo y aplicación de estos modelos, cuya estimación resulta más compleja que otros modelos multivariantes como la regresión o el análisis factorial.

---

<sup>2</sup> La modelización de ecuaciones estructurales se basa en relaciones causales, en las que el cambio de una variable se supone que produce un cambio en otra variable (Heise, 1975).

---

Habitualmente incluyen múltiples variables observables y múltiples variables no observables (variables latentes, también llamadas constructos). En palabras de Bollen (1989): "Podemos mirar estos modelos de diversos modos. Son ecuaciones de regresión con supuestos menos restrictivos, que permiten errores de medida tanto en las variables criterio (independientes) como en las variables dependientes. Consisten en análisis factoriales que permiten efectos directos e indirectos entre los factores. Habitualmente incluyen múltiples indicadores y variables latentes. Resumiendo, engloban y extienden los procedimientos de regresión, el análisis econométrico y el análisis factorial."

Ésta es precisamente, una de las diferencias más importantes entre los SEM y otras técnicas estadísticas multivariantes que realizan el análisis de modelos (más o menos complejos) que únicamente incorporan mediciones directamente observables. Junto a ello, otra de las principales características de los SEM, señalada por Bollen, reside en el hecho de que una misma variable puede comportarse, dentro de un mismo modelo, como variable respuesta en una ecuación y aparecer como una variable explicativa en otra ecuación. Así como también es posible, especificar un efecto recíproco, en el que dos variables produzcan efectos la una sobre la otra, mediante un proceso de *feedback*.

La aplicación de este tipo de modelos requiere de un diseño a priori, para el cual el investigador se apoya en la teoría de aquello que busca explicar. Este diseño a priori se conoce como "modelo teórico", consistente en un conjunto sistemático de relaciones (entre variables) que proporcionan una explicación consistente y comprensiva del fenómeno que se pretende estudiar. Dichas relaciones están definidas por una serie de ecuaciones que describen las estructuras de las relaciones establecidas (relaciones causales, de regresión con respuesta múltiple, correlaciones, etc.). Este modelo teórico se puede representar bien a través del conjunto de ecuaciones que lo estructuran o bien a través de los "path diagrams", que sirven

además, para resumir gráficamente, el conjunto de hipótesis sobre las que se asienta el modelo.

Respecto a su estimación, los SEM se basan en las correlaciones existentes entre las variables medidas en una muestra de sujetos de manera transversal. Por tanto, para poder realizar las estimaciones, basta con medir a un conjunto de sujetos en un momento dado. Este hecho hace especialmente atractivos estos modelos. Ahora bien, hay que tener en cuenta que las variables deben permitir el cálculo de las correlaciones y por ello deben ser variables cuantitativas, preferentemente continuas.

Para entender la fundamentación de los modelos de ecuaciones estructurales, es necesario reorientar nuestro conocimiento de lo que significa el concepto de ajuste de un modelo. En regresión lineal, cuando hablamos de las estimaciones de los parámetros, escogemos aquellas estimaciones que mejor ajustaban el modelo a los datos, en el sentido de que minimizaban los errores de predicción cometidos con el modelo para el conjunto de sujetos de la muestra, con el método de mínimos cuadrados.

Por el contrario, en los SEM, lo que se pretende ajustar son las covarianzas entre las variables, en vez de buscar el ajuste de los casos. En lugar de minimizar la diferencia entre los valores pronosticados y los observados a nivel individual, se minimiza la diferencia entre las covarianzas muestrales y las covarianzas pronosticadas por el modelo estructural. Este es el motivo por el que también se han denominado modelos de estructura de covarianzas. En otras palabras, la hipótesis de partida de los modelos basados en ecuaciones estructurales es que reproduce exactamente la matriz de varianzas y covarianzas que se estudian.

AMOS, software empleado en la obtención de las estimaciones que se presentarán en el siguiente punto, consiste precisamente en generar una matriz de varianzas y covarianzas del modelo diseñado por el investigador, y en compararla con la matriz real de varianzas y covarianzas que se esté estudiando, para determinar hasta qué punto se diferencian. Así, cuanto más parecidas sean, mejor será el modelo, puesto que ello querrá decir que el modelo reproduce el entramado de relaciones existente en la realidad.

### 1. Elementos de un modelo de ecuaciones estructurales

Un modelo de ecuaciones estructurales completo consta de dos partes fundamentales: el sub-modelo de medida y el sub-modelo de relaciones estructurales. El sub-modelo de medida contiene la manera en que cada constructo<sup>3</sup>, o variable latente, está medido mediante sus indicadores observables, los errores que afectan a las mediciones y las relaciones que se espera encontrar entre los constructos cuando éstos están relacionados entre sí.

Por su parte, el sub-modelo de relaciones estructurales es el que realmente se desea estimar. Contiene los efectos y relaciones entre los constructos. Es similar a un modelo de regresión, pero puede contener además efectos concatenados y bucles entre variables. Además, contiene los errores de predicción (que son distintos de los errores de medición).

---

<sup>3</sup> A partir de aquí se empleará la terminología propia de los modelos de ecuaciones estructurales para referirnos a las variables latentes utilizando indistintamente los términos constructo o variable latente. Se trata de variables que no son directamente observables, medidas a través de variables indicadoras o indicadores (ítems), que sí son observables directamente.

A modo de ilustrar gráficamente cómo es la estructura de un sub-modelo de medida y de un sub-modelo estructural, en segundo epígrafe de este capítulo se adjunta la Figura 2, en virtud de la cual se apreciará de una forma rápida y sencilla las diferencias existentes entre los elementos que integran cada uno de estos dos sub-modelos.

Existen dos casos excepcionales en los que el modelo no contiene ambas partes y que se usan con relativa frecuencia. En primer lugar, los modelos de análisis factorial confirmatorio sólo contienen el modelo de medida y las relaciones entre las variables latentes sólo pueden ser de tipo correlacional. En segundo lugar, los modelos de análisis de rutas no contienen variables latentes; en su lugar, las variables observables son equiparadas con las variables latentes; consecuentemente, sólo existe el modelo de relaciones estructurales. Como contrapartida, los errores de medición y los errores de predicción se confunden en un único término común.

### 1.1. Tipos de variables en los modelos de ecuaciones estructurales

En un modelo de ecuaciones estructurales se distinguen distintos tipos de variables según sea su papel y según sea su medición:

- Variable observada o indicador. Variable que se mide a los sujetos. Por ejemplo, las preguntas de un cuestionario.
- Variable latente. Característica que se desearía medir pero que no se puede observar. En consecuencia, que está libre de error de medición. Por ejemplo, una dimensión de un cuestionario o un factor en un análisis factorial exploratorio.
- Variable error. Representa tanto los errores asociados a la medición de una variable como el conjunto de variables que no han sido contempladas en el

modelo y que pueden afectar a la medición de una variable observada. Se considera que son variables de tipo latente por no ser observables directamente.

- El error asociado a la variable dependiente representa el error de predicción.
- Variable de agrupación. Variable categórica que representa la pertenencia a las distintas subpoblaciones que se desea comparar. Cada código representa una subpoblación.
- Variable exógena. Variable que afecta a otra variable y que no recibe efecto de ninguna variable. Las variables independientes de un modelo de regresión son exógenas.
- Variable endógena. Variable que recibe efecto de otra variable. La variable dependiente de un modelo de regresión es endógena. Toda variable endógena debe ir acompañada de un error.

### 1.2. Los diagramas estructurales. "Path-diagrams"

Para representar un modelo causal y las relaciones que se desea incluir en él se acostumbra a utilizar diagramas similares a los diagramas de flujo. Estos diagramas se denominan diagramas causales, gráfico de rutas, diagramas de senderos<sup>4</sup> o diagramas estructurales.

El diagrama estructural de un modelo es su representación gráfica y es de gran ayuda a la hora de especificar el modelo y los parámetros contenidos en él. En definitiva, se trata de un gráfico en el que se encuentran representadas las relaciones de causalidad que se supone que existen en un conjunto de variables.

---

<sup>4</sup> En los diagramas de senderos o diagramas estructurales, los parámetros de las ecuaciones estructurales reciben el nombre de coeficientes de Wright, que son los que constituyen las incógnitas, y cuyo valor se determina resolviendo el sistema de ecuaciones estructurales.



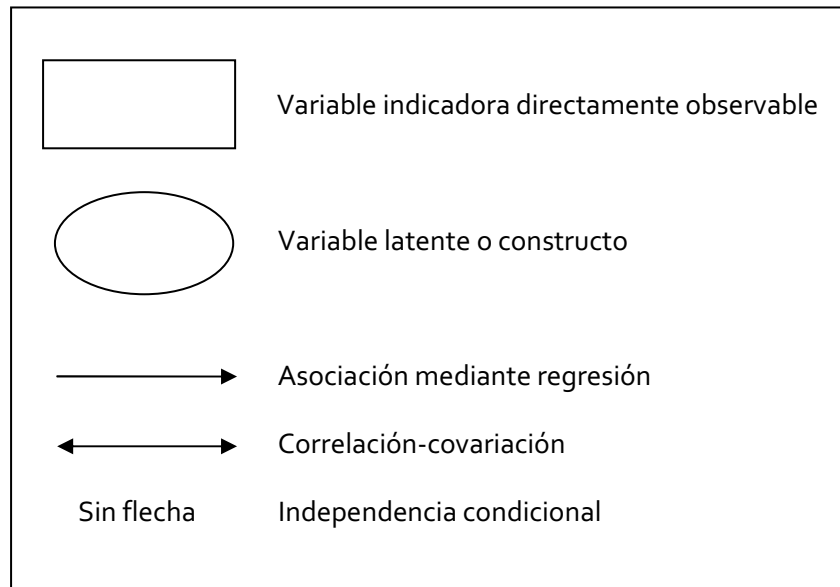
De hecho, los programas actuales, como el AMOS, permiten realizar la definición del modelo en su totalidad al representarlo en el interfaz gráfico. A partir del diagrama estructural el propio programa deriva las ecuaciones del modelo e informa de las restricciones necesarias para que esté completamente identificado.

Los diagramas estructurales siguen unas convenciones particulares que es necesario conocer para poder derivar las ecuaciones correspondientes:

- Las variables observables se representan encerradas en rectángulos.
- Las variables no observables (latentes) se representan encerradas en óvalos o círculos.
- Los errores (sean de medición o de predicción) se representan sin rectángulos ni círculos (aunque algunos programas las dibujan como variables latentes, como en el modelo que se presenta en este trabajo de investigación).
- Las relaciones bidireccionales (covariación entre dos variables exógenas o dos términos de perturbación) se representan como vectores curvos con una flecha en cada extremo. El parámetro asociado indica la covarianza.
- La falta de flecha entre dos variables significa que dichas variables no están directamente relacionadas, aunque sí podrán estarlo indirectamente.

Estos símbolos o representaciones gráficas ayudan a comprender rápidamente qué tipo de variables componen el modelo de ecuaciones estructurales como el tipo o tipos de relaciones que se establecen entre ellas. A modo aclaratorio, en la Figura 1, se resume esta forma de representar tanto los diferentes tipos de variables de un SEM como los tipos de relaciones que entre ellas se puedan producir.

Figura 1. Convenciones "path diagrams"



Cualquier efecto estructural se representa como una flecha recta y unidireccional, cuyo origen es la variable predictor y cuyo final, donde se encuentra la punta de la flecha, es la variable dependiente. Es decir, las variables a las que llega alguna flecha se denominan endógenas y aquellas a las que no llega ninguna flecha exógenas.

Las variables endógenas están afectadas por un término de perturbación aleatorio que simplemente se incluye en el diagrama como una flecha adicional a la variable endógena.

Toda variable que reciba efecto de otras variables del modelo deberá incluir también un término error.

- Los parámetros del modelo se representan sobre la flecha correspondiente.
- Aunque no es necesario que el usuario lo especifique, los programas suelen incluir, junto a cada variable, su varianza y, si se trata de una variable dependiente, su correspondiente proporción de varianza explicada.

Junto a ello, es necesario aclarar que, a la vista del diagrama estructural, podremos diferenciar rápidamente si el conjunto de ecuaciones estructurales constituye un modelo recursivo o no recursivo.

Es decir, en función de las características del diagrama podremos diferenciar entre modelos en los que los errores (también denominados “perturbaciones”) no están relacionados y todos los efectos causales son unidireccionales (modelos recursivos) y, aquellos modelos denominados no recursivos en los que existen lazos de retroalimentación o puedan tener errores correlacionados.

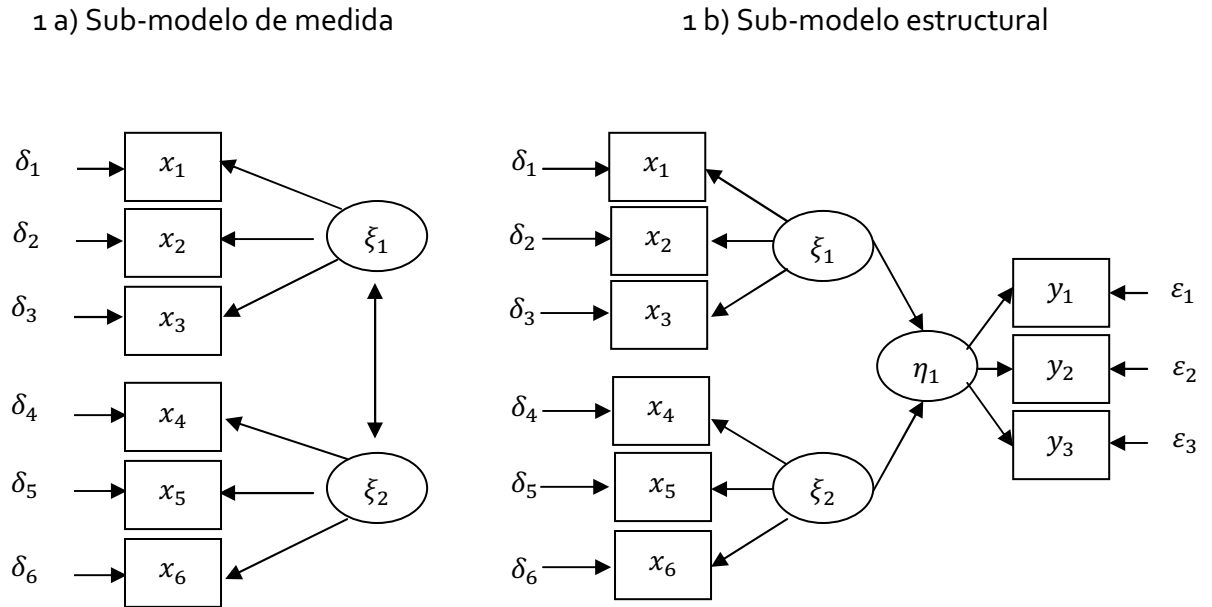
Para finalizar con la exposición de los tipos de “path diagrams” de los modelos de ecuaciones estructurales, y dado que ya se ha expuesto que los SEM están formados por un sub-modelo de medida y un sub-modelo estructural<sup>5</sup>, se adjunta la Figura 2 que ayudará a par identificar los elementos que los conforman y, por tanto, las diferencias entre uno y otro.

---

<sup>5</sup> Únicamente existen dos excepciones en las que los SEM no incorporan ambos sub-modelos: modelos de análisis factorial confirmatorio y modelos de análisis de rutas en los que no hay variables latentes.

---

Figura 2. "Path diagrams" de un sub-modelo de medida y un sub-modelo estructural



### 1.3. Relaciones entre variables

Empecemos por definir los tipos de relaciones causales que pueden establecerse entre dos variables, por ejemplo,  $v_1$  y  $v_2$ , para que covaríen:

- En primer lugar,  $v_1$  y  $v_2$  pueden covariar si  $v_1$  causa  $v_2$ , es decir, asumir un modelo de regresión en el que  $v_2$  fuese la variable respuesta y  $v_1$  la variables predictora, cuya representación a través de un "path diagram" quedaría expresado a través de la Figura 2.3a. Igualmente, también pueden covariar si  $v_2$  causa  $v_1$ , ante lo que cual, estaríamos hablando de una regresión de de  $v_1$  sobre  $v_2$ ; relación que se expresa mediante el "path diagram" contenido en la figura 2.3b. En ambos casos, las relaciones que se

establecen son relaciones directas, que a su vez, también podrían ser recíprocas; en cuyo caso su representación vendría dado por la figura 2.3c.

- Así mismo,  $v_1$  y  $v_2$  también covariarán si ambas tienen una causa común,  $v_3$ . En tal caso, estaríamos ante lo que se ha dado en conocer como relación espúrea, cuya representación a través de "path diagram" se expresa a través de la figura 2.3d.
- Otro tipo de relación en virtud de la cual  $v_1$  y  $v_2$  pueden covariar, es a través de una tercera variable interviniente  $v_3$ ; estableciéndose entre la primera y la segunda de ellas, lo que se conoce como una relación indirecta, tal y como se puede apreciar en la figura 2.3e.
- Por último, otra forma de covariación entre dos variables ( $v_1$  y  $v_2$ ) es la representada en la figura 2.3f, en donde se emparentan con la relación indirecta y con la relación espúrea. La diferencia entre la figura 2.3d, la figura 2.3e y la figura 2.3f, es que en esta última, tanto  $v_1$  como  $v_3$  son variables exógenas y carecen de mecanismo causal explícito que las relaciones entre sí: no se especifica de qué tipo es la relación entre  $v_1$  y  $v_3$  y se deja la covariación entre ambas variables como no explicada. El coste que se deriva de esta indeterminación se refleja en la imposibilidad de discernir si  $v_3$  contribuye a la covariación entre  $v_1$  y  $v_2$  por vía indirecta o espúrea. La solución a dicha indeterminación consiste en denominar a esta relación como "efecto conjunto".

Gráfico 1. Relaciones entre variables. Formas de covariación.




Figura 2.3a.



Figura 2.3b.




Figura 2.3c.




Figura 2.3d.




Figura 2.3e.




Figura 2.3f.


Una vez que ya se han expuesto todas las posibles formas de covariación entre dos variables, corresponde establecer de forma intuitiva la relación entre los parámetros y las covariaciones entre las variables bajo la lógica del “path analysis” con las llamadas reglas de descomposición. Con ello, conseguiremos, en última instancia, estimar los parámetros a partir de las relaciones entre variables.

En primer lugar, tanto las varianzas como las covarianzas de las variables exógenas, constituyen por sí mismas, parámetros del modelo. En virtud de las reglas de descomposición, para el resto de varianzas y covarianzas del modelo se entiende que:

- La covarianza entre dos variables es igual a la suma del efecto directo, los efectos indirectos, espúreos y conjuntos. El origen de la relación puede estar en cualquiera de estas dos variables consideradas (en el caso de los efectos directos o indirectos), en una tercera variable (en el caso de efectos espúreos), o una covarianza entre dos variables exógenas (en el caso de los efectos conjuntos). El efecto se calcula como el producto de la varianza de la variable de partida (o covarianza de partida en su caso) por todos y cada uno de los parámetros asociados a las flechas recorridas hasta llegar a unir las dos variables de interés. Hay que tener que cuenta, que al calcular un efecto no se puede pasar por una misma variable más de una vez.
- La varianza de una variable dependiente es igual a la varianza del término de perturbación más la varianza explicada por otras variables del modelo. A su vez, esta varianza explicada puede expresarse en función de todas las variables explicativas con efecto directo sobre la dependiente, como suma de todos los productos entre estos efectos directos y las covarianzas entre la variable dependiente y la explicativa relacionadas por dichos efectos.

A continuación, y para facilitar la comprensión de la estructura de un modelo de ecuaciones estructurales, se presenta en el Gráfico 2 el modelo inicial con el que se inicia el análisis causal con ecuaciones estructurales de la satisfacción ciudadana con los servicios municipales y que se desarrollará detenidamente en el capítulo tercero.

Gráfico 2. Modelo de Ecuaciones Estructurales inicial.





En el Gráfico 2 podemos diferenciar entre las dos partes integrantes de los modelos de ecuaciones estructurales de los que ya se ha hablado: el sub-modelo de medida y el sub-modelo estructural. El primero de ellos está formado por tres constructos ó variables latentes  $\xi_1, \xi_2$  y  $\xi_3$ , estableciéndose correlaciones entre  $\xi_1$  y  $\xi_2$ , entre  $\xi_2$  y  $\xi_3$  y entre  $\xi_1$  y  $\xi_3$ . Puesto que únicamente se relacionan entre sí mediante mecanismos de correlación, podemos decir que estas tres variables latentes funcionan como variables latentes exógenas.

La variable latente  $\xi_1$  se crea a partir de la saturación 4 variables observadas  $x_1, \dots, x_4$ , la variable latente  $\xi_2$  se crea a partir de  $x_5, \dots, x_8$ , mientras que  $\xi_3$  se crea a partir de  $x_9, \dots, x_{13}$ . Las elipses<sup>6</sup> asociadas a cada una de las variables observadas representan los errores del modelo de medida.

Por su parte, las variables  $\eta_1$  (creada a partir de las variables observadas  $y_1$  e  $y_2$ ) y  $\eta_2$  (creada a partir de las variables observadas  $y_3, \dots, y_5$ ) son las únicas variables latentes que reciben el efecto de otras variables latentes, es decir, son las variables latentes endógenas del modelo. Más concretamente,  $\eta_1$  recibe el efecto directo de  $\xi_3$ ; efecto que también recibe  $\eta_2$  aunque de forma indirecta a través de  $\eta_1$  (ver Gráfico 1), y por su parte,  $\eta_2$  recibe el efecto directo de  $\xi_1, \xi_2$  y  $\eta_1$ . De esta forma, entendemos que tanto  $\eta_1$  como  $\eta_2$  funcionan como variables dependientes y, por tanto, el error que cada una de ellas lleva asociado es un error de predicción y no de medida. Toda esta estructura de relaciones conforma el sub-modelo estructural.

Por último, el gráfico muestra que modelo de ecuaciones estructurales con el que se inicia el estudio es de tipo recursivo, puesto que no existen errores correlacionados ni lazos de retroalimentación.

---

<sup>6</sup> Tal y como se ha dicho con anterioridad en el punto 1.2. los errores, tanto de medición como de medida no se representan en rectángulos o círculos, sin embargo, se ha optado por representarlos mediante elipses porque ésta es la representación gráfica habitual utilizada en la literatura sobre modelos de ecuaciones estructurales, puesto que se consideran variables latentes por no ser observables directamente.

---

## 2. Construcción del modelo estructural

El modelo teórico debe especificar las relaciones que se espera encontrar entre las variables (correlaciones, efectos directos, efectos indirectos, bucles). Si una variable no es directamente observable, deben mencionarse los indicadores que permiten medirla. Lo normal es formular el modelo en formato gráfico; a partir de ahí es fácil identificar las ecuaciones y los parámetros.

Una vez formulado el modelo, cada parámetro debe estar correctamente identificado y ser derivable de la información contenida en la matriz de varianzas-covarianzas.

Existen estrategias para conseguir que todos los parámetros estén identificados, como por ejemplo, utilizar al menos tres indicadores por variable latente e igualar la métrica de cada variable latente con uno de sus indicadores (esto se consigue fijando arbitrariamente al valor 1 el peso de uno de los indicadores). Aún así, puede suceder que el modelo no esté completamente identificado, lo que querrá decir que se está intentando estimar más parámetros que el número de piezas de información contenidas en la matriz de varianzas-covarianzas. En ese caso habrá que imponer más restricciones al modelo (fijando el valor de algún parámetro) y volver a formularlo.

Por otra parte, una vez seleccionadas las variables que formarán parte del modelo, hay que decidir cómo se medirán las variables observables. Estas mediciones (generalmente obtenidas mediante escalas o cuestionarios) permitirán obtener las varianzas y las covarianzas en las que se basa la estimación de los parámetros de un modelo correctamente formulado e identificado (asumimos que estamos trabajando

con una muestra representativa de la población que se desea estudiar y de tamaño suficientemente grande).

Una vez estimados los parámetros del modelo se procede, en primer lugar, a valorar su ajuste. Si las estimaciones obtenidas no reproducen correctamente los datos observados, habrá que rechazar el modelo y con ello la teoría que lo soportaba, pudiendo pasar a corregir el modelo haciendo supuestos teóricos adicionales.

En segundo lugar, se procede a hacer una valoración técnica de los valores estimados para los parámetros. Su magnitud debe ser la adecuada, los efectos deben ser significativamente distintos de cero, no deben obtenerse estimaciones impropias (como varianzas negativas), etc.

Puede ocurrir que alguna de las estimaciones tenga un valor próximo a cero; cuando ocurre esto es recomendable simplificar el modelo eliminando el correspondiente efecto. Por último, el modelo debe interpretarse en todas sus partes. Si el modelo ha sido aceptado como una buena explicación de los datos será interesante validarlo con otras muestras y, muy posiblemente, utilizarlo como explicación de teorías de mayor complejidad que se desee contrastar.

En general, en el desarrollo de un modelo de ecuaciones estructurales es necesario desarrollar cuatro fases: la especificación, la identificación, la estimación y, por último, la evaluación y la interpretación<sup>7</sup> de dicho modelo. A continuación se apuntará en qué consiste cada una de estas fases.

---

<sup>7</sup> La evaluación e interpretación del modelo de ecuaciones estructurales se expondrá detenidamente en el punto cuarto de este capítulo.

---

### 2.1. Fase de especificación

El sub-modelo estructural es aquel componente del modelo general que describe las relaciones causales entre variables latentes. Las relaciones entre las variables directamente observables se incluyen cuando éstas no actúan como indicadores de las variables latentes.

En definitiva, habrá tantas ecuaciones estructurales como constructos latentes (variables endógenas) que sean explicadas por otras variables exógenas (latentes u observadas). La estructura que sigue este tipo de ecuaciones de los sub-modelos estructurales se puede expresar de la siguiente forma:

$$\eta = B\eta + \Gamma\xi + \zeta \quad (1)$$

donde:

“ $\eta$ ” (eta) es un vector “ $p \times 1$ ” de variables endógenas latentes (esto es, variables predictoras o variables no explicadas por otras incluidas en el modelo).

“ $\xi$ ” (xi) es un vector “ $q \times 1$ ” de variables exógenas latentes (esto es, variables predictoras o variables no explicadas por otras incluidas en el modelo).

“ $\Gamma$ ” (gamma) es una matriz “ $p \times q$ ” de coeficientes ( $\gamma_{ij}$ ) que relacionan las variables latentes exógenas ( $\xi$ ) con las endógenas ( $\eta$ ). Indican que una unidad de cambio en la variable exógena  $\xi_i$  resulta en un cambio en  $\eta_i$   $\gamma_{ij}$  unidades, manteniendo todas las demás variables constantes. Este coeficiente estructural se interpreta, al igual que  $\beta_{ij}$  como efectos directos de las variables endógenas.

“ $\beta$ ” (beta) es una matriz “ $q \times q$ ” de coeficientes que relacionan las variables latentes endógenas entre sí. Cada  $\beta_{ij}$  indica una unidad de cambio en la variable endógena  $\eta_i$ , manteniendo todas las demás variables constantes. Para cada efecto hipotetizado de una variable latente endógena en otra, de las mismas características, se tendrá un coeficiente estructural  $\beta_{ij}$ .

" $\zeta$ " (zeta) es un vector " $q \times 1$ " de errores o términos de perturbación. Indican que las variables endógenas no son perfectamente predichas por las ecuaciones estructurales. Se supone que no existe correlación entre los errores y las variables exógenas.

Por otra parte, las variables latentes están relacionadas con variables observables a través del sub-modelo de medida, que está definido tanto por variables endógenas como por variables exógenas a través de las siguientes expresiones:

$$y = \Lambda_y \eta + \varepsilon \quad y \quad x = \Lambda_x \xi + \delta \quad (2)$$

donde:

$\eta$  es un vector  $m \times 1$  de variables latentes endógenas,

$\xi$  es un vector  $k \times 1$  de variables latentes endógenas,

$\Lambda_x$  es una matriz  $q \times k$  de coeficientes de variables exógenas,

$\Lambda_y$  es una matriz  $p \times m$  de coeficientes de variables endógenas,

$\delta$  es un vector  $q \times 1$  de errores de medición para los indicadores exógenos y,

$\varepsilon$  es un vector  $p \times 1$  de errores de medición para los indicadores endógenos.

## 2.2. Fase de estimación

Para la aplicación de este tipo de modelos sobre los datos de la encuesta de satisfacción ciudadana se han empleado diferentes métodos de estimación de los parámetros, con el objetivo de determinar cuál de ellos presenta un mejor ajuste: máxima verosimilitud (ML), mínimos cuadrados ponderados<sup>8</sup> (WLS) y mínimos cuadrados generalizados (GLS)<sup>9</sup>

La aplicación del primero de ellos se debe a que proporciona estimaciones consistentes, eficientes y no sesgadas con tamaños de muestra suficientes, siendo capaz de facilitar la convergencia de las estimaciones con los parámetros aún en ausencia de normalidad.

Sin embargo, algunos estudios de simulación sugieren que en condiciones de no normalidad las estimaciones aún siendo consistentes no resultan necesariamente eficientes, resultando recomendable con muestras pequeñas, la estimación por ML con la aplicación de procedimientos bootstrap, puesto que permite obtener empíricamente (mediante técnicas de remuestreo) estimaciones de los errores estándar de los parámetros del modelo, independientemente de su distribución. Además, la aplicación de métodos bootstrap permite determinar intervalos de confianza para las estimaciones.

Por su parte, cuando los datos no siguen una distribución normal, el método de estimación más recomendado es un método de distribución libre asintótica (ADF), siendo el método de mínimos cuadrados ponderados uno de los más utilizados.

---

<sup>8</sup> Método que en el programa AMOS aparece bajo la etiqueta de método de distribución libre asintótica (ADF).

<sup>9</sup> Como caso especial de estimación por mínimos cuadrados ponderados (WLS).

De esta forma, en el caso de que la distribución de las variables observadas no esté muy alejada de una distribución normal, se recomienda emplear ML. A continuación se describen brevemente ambos métodos de estimación.

### 2.2.1. Estimación por Máxima Verosimilitud (ML)

Máxima Verosimilitud es el método de estimación más utilizado en el ajuste de modelos de ecuaciones estructurales. Como ya se ha dicho, la estimación por ML requiere que las variables observadas mantengan una distribución normal, sin embargo, la violación de la condición de normalidad multivariante no afecta a la capacidad del método para estimar de forma no sesgada los parámetros del modelo. Además, cuando el tamaño de muestra aumenta la distribución de los estimadores se aproximan a la distribución normal.

La función de log-verosimilitud viene dada por:

$$\log L = -\frac{1}{2}(N - 1)\{\log|\Sigma(\theta)| + \text{tr}[S\Sigma(\theta)^{-1}]\} + c \quad (3)$$

dónde:

log es un logaritmo natural,

L es la función de verosimilitud,

N es el tamaño de la muestra,

$\theta$  es el vector de parámetros,

S es la matriz de covarianzas empírica,

$\Sigma(\theta)$  es la matriz de covarianzas del modelo y  $|\Sigma(\theta)|$  su determinante,

tr es la traza de la matriz y,

c es una constante.

Maximizar  $\log L$  es equivalente a minimizar la siguiente función:

$$F_{ML} = \log|\Sigma(\theta)| - \log|S| + \text{tr}[S\Sigma(\theta)^{-1}] - p \quad (4)$$

donde:

$F_{ML}$  es el valor de la función de ajuste evaluada al finalizar la estimación y,  
 $p$  es el número de variables observadas.

#### 2.2.2. Estimación por Mínimos Cuadrados Ponderados (WLS)

Cuando la condición de normalidad de los datos no se cumple, una de las posibilidades para la estimación de los parámetros son métodos alternativos como el criterio de mínimos cuadrados ponderados (Weighted Least Squares), para cuya aplicación no es necesaria dicha condición; método de estimación que en el programa AMOS se encuentra bajo la nomenclatura de método de estimación de distribución libre asintótica (ADF).

Una de las ventajas que presenta este método es que permite introducir en los análisis variables ordinales, variables dicotómicas y variables continuas que no se ajusten a criterios de normalidad.

Este método minimiza la siguiente función de ajuste:

$$F_{WLS} = [s - \sigma(\theta)]'W^{-1}[s - \sigma(\theta)] \quad (5)$$

dónde:

$s$  es el vector de elementos no redundantes en la matriz de covarianzas empírica,

$\sigma(\theta)$  es el vector de elementos no redundantes en la matriz de covarianzas del modelo,



$\theta$  es un vector de  $(t \times 1)$  parámetros,

$W^{-1}$  es una matriz  $(k \times k)$  definida positiva con  $k = p(p + 1)/2$  y  $p =$  número de variables observadas.

Sin embargo, y a pesar de presentar ciertas ventajas, la estimación por mínimos cuadrados ponderados también presenta importantes restricciones y desventajas de las que hablaremos a continuación.

Si bien, su punto fuerte reside en poder realizar la estimación de los parámetros sin la necesidad de que las variables observadas sigan una distribución normal, el valor del estadístico ji-cuadrado que proporciona únicamente será preciso cuando la muestra sea lo suficientemente grande.

La limitación de este método se puede comprobar con el hecho de que la matriz de pesos aumentará rápidamente al incrementarse el número de variables indicadoras. De este modo, la matriz de covarianzas asintótica, de orden  $(k \times k)$ , donde  $k = p(p + 1)/2$  y  $p$  es el número de variables observadas, la matriz de pesos correspondiente a un modelo con 10 variables debería ser del orden  $(55 \times 55)$ , con 1540 elementos no redundantes.

Es por ello, por lo que la estimación por mínimos cuadrados ponderados, en comparación con el método de máxima verosimilitud, requiere muestras mucho más grandes para obtener estimaciones consistentes y eficientes. O dicho de otro modo, si las variables observadas no están muy alejadas de la distribución normal, la recomendación es aplicar ML.

### 2.2.3. Estimación por Mínimos Cuadrados Generalizados (GLS)

Se trata de un caso especial dentro de la estimación por mínimos cuadrados ponderados.

Bajo condiciones de normalidad multivariante, la función de ajuste del método de estimación por mínimos cuadrados ponderados puede reescribirse de la siguiente forma:

$$F_{WLS} = \frac{1}{2} \text{tr}\{[S - \Sigma(\theta)]V^{-1}\}^2 \quad (6)$$

donde:

tr es la traza de la matriz,

S es la matriz de covarianzas empírica,

$\Sigma(\theta)$  es la matriz de covarianzas del modelo,

$\theta$  es un vector de parámetros ( $t \times 1$ ) y,

$V^{-1}$  es la matriz de pesos  $p \times p$ . Se trata de una matriz de pesos de bajas dimensiones.

El método de estimación por mínimos cuadrados generalizados sigue una función de ajuste similar, reemplazando de la expresión 6,  $V^{-1}$  por inversa de la matriz de covarianzas empírica, de modo que su función de ajuste se puede expresar como:

$$F_{GLS} = \frac{1}{2} \text{tr}\{[S - \Sigma(\theta)]S^{-1}\}^2 \quad (7)$$

En general, el método GLS se utiliza con frecuencia como un método de estimación asintóticamente equivalente a  $F_{ML}$ , puesto que se basa en los mismos criterios que la estimación por máxima verosimilitud y se puede emplear bajo las mismas condiciones. Sin embargo, la estimación por máxima verosimilitud resulta más apropiada cuando el tamaño de muestra es pequeño. Además, resulta inapropiado cuando el modelo aumenta en tamaño y complejidad.

---

### 2.3. Fase de identificación

Un modelo estará identificado si los parámetros del modelo completo (modelo estructural y modelo de medida, juntos) pueden estimarse a partir de los elementos de la matriz de covarianzas de las variables observables.

La regla conocida como “regla del conteo”, se emplea para identificar los modelos de ecuaciones estructurales. Se denotará al número total de variables con  $s = p + q$ , siendo  $p$  las variables endógenas y  $q$  las exógenas. Por consiguiente, el número de elementos no redundantes en  $\Sigma$  es igual a  $\frac{1}{2} s(s+1)$ .

Además, se denota al número total de parámetros a ser estimados en el modelo como  $t$ , por lo que, para realizar la identificación del modelo se debe tener la siguiente condición necesaria  $t \leq \frac{1}{2} s(s+1)$ .

- Si se tiene la igualdad, se dice que el modelo está identificado.
- Si  $t$  es estrictamente menor que  $\frac{1}{2} s(s+1)$ , se dice que el modelo está sobre identificado.
- Si  $t$  es mayor que  $\frac{1}{2} s(s+1)$ , entonces el modelo no está identificado.

Cuando el modelo de ecuaciones estructurales es recursivo, está también identificado.

### 2.4. Fase de evaluación e interpretación de modelos ecuaciones estructurales

Una vez que el modelo esté identificado y se haya realizado la estimación de los parámetros, únicamente restan dos pasos que resultan fundamentales para cualquier análisis: la evaluación e interpretación del mismo a fin de contrastar si los datos se han ajustado al modelo propuesto.

La utilidad del modelo vendrá dada por su capacidad para explicar la realidad observada. Esta capacidad debe evaluarse tanto para el conjunto del modelo, como para cada una de las relaciones expresadas en él.

En sentido general, podemos decir que existen tres alternativas para evaluar el modelo: la evaluación del ajuste del modelo global<sup>10</sup>, la evaluación del ajuste del modelo de medida y la evaluación del ajuste del modelo estructural. A continuación se enumerarán cada una de las medidas existentes para la evaluación de modelos de ecuaciones estructurales.

En definitiva, hay que destacar que para cada estimación aparecerán asociados un gran número de índices de bondad de ajuste que serán necesarios interpretar para concluir si el modelo es consistente con los datos empíricos. Será su correcta interpretación, tanto de forma individual, como en sentido global, lo que determine si podemos aceptar el modelo planteado.

Puesto que el número de medidas de ajuste y test de bondad de ajuste necesarios para la evaluación e interpretación de los modelos de ecuaciones estructurales, en el tercer punto de este capítulo se describen y desarrollan con detenimiento los más utilizados tradicionalmente en la literatura especializada.

### 3. Bondad de ajuste de los modelos de ecuaciones estructurales

En primer lugar se expondrá el ajuste del sub-modelo de medida, seguido del ajuste del sub-modelo estructural y, finalmente, se desarrollarán las medidas de ajuste

---

<sup>10</sup> Entre las que se encuadra al test chi-cuadrado.

global más importantes en la evaluación e interpretaciones de los modelos de ecuaciones estructurales.

### 3.1. Ajuste del modelo de medida

Tal y como ya se ha apuntado, el modelo de medida se construye a través de la aplicación de análisis factorial, relacionando indicadores con variables latentes; relación en la que subyace la existencia de una relación lineal entre el concepto no directamente observable y su(s) manifestación(es) observable(s).

El empleo de modelos factoriales es muy habitual en las ciencias sociales y del comportamiento ante la incapacidad de medir directamente conceptos tan amplios como el que se presenta en este trabajo de investigación; la satisfacción ciudadana con los servicios municipales.

El análisis factorial tiene mucho en común con otro método de reducción de la dimensión, más concretamente, con el análisis de componentes principales. Ambos métodos buscan crear nuevas variables o factores (no directamente observables) que expliquen los datos, para lo que resulta necesario que las variables originales no estén incorreladas, porque de estarlo no habría nada que explicar de las variables.

Consideramos un conjunto de  $p$  variables observadas  $X' = (x_1, x_2, \dots, x_p)$  que se asume relacionadas con un número dado de variables latentes  $f_1, f_2, \dots, f_k$ , donde  $k < p$ , mediante una relación del tipo:

$$\begin{aligned}x_1 &= \lambda_{11}f_1 + \dots + \lambda_{1k}f_k + u_1 \\ &\vdots \\ x_p &= \lambda_{p1}f_1 + \dots + \lambda_{pk}f_k + u_p\end{aligned}\tag{8}$$

o lo que es lo mismo:

$$X = \Lambda f + u \quad (9)$$

donde

$$\Lambda = \begin{pmatrix} \lambda_{11} & \cdots & \lambda_{1k} \\ \vdots & \ddots & \vdots \\ \lambda_{p1} & \cdots & \lambda_{pk} \end{pmatrix}, f = \begin{pmatrix} f_1 \\ \vdots \\ f_k \end{pmatrix}, u = \begin{pmatrix} u_1 \\ \vdots \\ u_p \end{pmatrix} \quad (10)$$

Los  $\lambda_{ij}$  son los pesos factoriales que muestran como cada  $x_i$  depende de factores comunes y se usan para interpretar los factores. Es decir, valores altos relacionan un factor con la correspondiente variable observada y así se puede caracterizar cada factor.

Se asume, además, que los residuos  $u_1, u_2, \dots, u_p$  están incorrelados entre sí y con los factores  $f_1, f_2, \dots, f_k$ . Cada variable  $u_i$  es particular para cada  $u_i$  y se conoce como variable específica.


Dado que los factores son variables latentes no directamente observables, se puede fijar de forma arbitraria su media en 0 y su varianza en 1, en otras palabras, las consideramos variables estandarizadas que, como ya se ha dicho, están incorreladas entre sí, de modo que los pesos factoriales resultan ser las correlaciones entre las variables directamente observables y los factores.

Si bien dentro del análisis factorial podemos diferenciar entre dos métodos de análisis distintos: Análisis Factorial Exploratorio (EFA) y Análisis Factorial Confirmatorio (CFA). Mientras que el Análisis Factorial Exploratorio (EFA) tiene como principal objetivo determinar del número de factores que subyacen a los datos, así como permitir que todos los indicadores saturan en todos los factores, y que todos los factores estén correlacionados, en el Análisis Factorial Confirmatorio (AFC) es que el

investigador quien debe concretar a priori todos los aspectos relevantes del modelo, aspectos que deben estar fundamentados en la teoría y en experiencia previa.

Así, antes de comenzar con el análisis, han de especificarse qué factores y qué indicadores forman parte del modelo, qué indicadores presentan saturaciones en cada factor, si existe o no relación entre los factores, y así sucesivamente. El AFC es, en consecuencia, un método de gran utilidad para el contraste tanto de hipótesis como de teorías<sup>11</sup>.

Gráfico 3. Ejemplo de Análisis Factorial Confirmatorio



En el gráfico anterior se representa un ejemplo simple de análisis factorial confirmatorio (CFA), en donde las variables directamente observables son  $X_1, X_2, \dots, X_8$ , los errores de medida asociados a cada uno de ellos son  $\delta_1, \delta_2, \dots, \delta_8$ , mientras que las variables latentes (constructos o factores) están representadas como  $\xi_1, \xi_2$  ( $xi1$  y  $xi2$ ).

<sup>11</sup> Hay que recordar que no siempre el CFA ha sido empleado con un carácter estrictamente "confirmatorio", pues son numerosos los estudios con aplicación de modelos de ecuaciones estructurales en los que la aplicación del CFA tiene un sentido más exploratorio, sobre todo, en aquellos casos en los que apenas existen teorías claras o bien pertenecen a cuestiones o áreas poco investigadas.

Las hipótesis que se busca contrastar en el ejemplo de CFA representado en la figura anterior se basan en que  $X_1, X_2, X_3, X_4$  miden el factor  $\xi_1$  y, por su parte,  $X_5, X_6, X_7, X_8$  miden el factor  $\xi_2$ . Además, tal y como se puede apreciar en el Gráfico 3, ambos factores covarían y, los errores asociados a cada una de las variables directamente observables son independientes.

Hay que señalar que las causas de los errores de medidas resultan desconocidas, por lo que se pueden considerar como variables exógenas que reflejan dos clases de varianza única: por una parte el error aleatorio y, por otra, la varianza sistemática debida a otros elementos que el indicador mide además del factor subyacente, tales como los efectos de un particular método de medida.

Desde el punto de vista práctico, en primer lugar es necesario examinar la significación estadística de cada carga obtenida entre el indicador y la variable latente correspondiente. En otras palabras, es el análisis factorial el que da lugar a lo que se conoce como modelo de medida, relacionando las variables latentes con las variables observables.

Una vez examinadas la significación de las cargas, corresponde ahora evaluar la fiabilidad de cada uno de los indicadores, así como la fiabilidad compuesta del constructo o variable latente. En este sentido, la fiabilidad de cada indicador vendrá dada por la proporción de varianza que tiene en común con el constructo. De este modo, se considera que un indicador debería tener al menos un 50% de su varianza en común con la variable latente. En otras palabras, el límite que se considera aceptable para esta medida de la fiabilidad compuesta es de .50.



Por otra parte, existe otra medida que habitualmente se utiliza para evaluar el ajuste del modelo de medida. Esta medida no es otra que la varianza extraída, que indica la cantidad global de varianza en los indicadores explicada por la variable latente. Sólo si este valor es superior a .50, se considera que los indicadores miden adecuadamente dicha variable latente.

### 3.2. Ajuste del modelo estructural

El análisis "Path" o de senderos es el que modeliza las relaciones entre las variables latentes, o lo que es lo mismo, el modelo de estructura; en donde se incorporan el error de medida y la relación entre constructos o variables latentes.

Para evaluar el ajuste del modelo estructural, corresponde en primer lugar, analizar la significación alcanzada por los coeficientes estimados. De este modo, cualquier parámetro estimado debe ser estadísticamente diferente de cero, o lo que es lo mismo, si consideramos un nivel de significación igual a .05.

Consecuentemente, un parámetro no significativo indicaría que la relación propuesta no tiene ningún efecto sustancial, por lo que debería ser eliminado y, a continuación, reformular el modelo.

Hay que tener en cuenta que, la magnitud de los coeficientes no está únicamente determinada por su significación de los parámetros, ya que otros factores como el tamaño muestral y la varianza de las variables dependientes e independientes (cuanto mayor es la magnitud de la relación y el tamaño muestral y cuanto menor es la varianza de las variables dependientes e independientes, mayor es la probabilidad de obtener una relación estadísticamente significativa).

### 3.3. Medidas de ajuste global

Diremos que existe un ajuste perfecto cuando haya una correspondencia perfecta entre la matriz reproducida por el modelo y la matriz de observaciones. Entre los índices identificados como de ajuste global, podemos diferenciar entre tres tipos de medidas: medidas absolutas de ajuste, medidas incrementales de ajuste y medidas de ajuste de parsimonia.

#### 3.3.1. Medidas absolutas de ajuste

Las medidas absolutas de ajuste, determinan el grado en que el modelo globalmente (modelo estructural y modelo de medida) predice la matriz de datos inicial. En este grupo podemos encuadrar al estadístico ji-cuadrado, el estadístico ji-cuadrado no centrado (NCP<sup>12</sup>). Junto a ellas, aparecen otras medidas como la raíz cuadrada del error cuadrático medio o "RMSEA"<sup>13</sup> ("Root Mean Square Error of Approximation"), en virtud de la cual la discrepancia entre la matriz reproducida por el modelo y la matriz de observaciones está medida en términos de la población y no en términos de la muestra; el conocido como índice de bondad de ajuste o "GFI"<sup>14</sup>, que aporta información sobre la variabilidad explicada por el modelo y cuyos valores oscilan entre 0 (no hay ajuste) y 1 (ajuste perfecto); y, por último, dentro de las medidas absolutas de ajuste resta mencionar al índice de bondad de ajuste relativo o "RGFI"<sup>15</sup>, que ayuda a evaluar la bondad de ajuste del modelo considerando el tamaño muestral y el número de indicadores.

---

<sup>12</sup> Igual al estadístico chi-cuadrado corregido por los grados de libertad. Se consideran aceptables valores lo más próximos a cero.

<sup>13</sup> Valores inferiores a .08 son indicativos de un buen ajuste del modelo.

<sup>14</sup> Valores a partir de .90 indicarían un ajuste aceptable.

<sup>15</sup> Se consideran aceptables modelo cuyo RGFI tiene un valor no inferior .90.

Es decir, en general, la mayor parte de estas medidas están comprendidas entre el rango entre cero (mal ajuste) y uno (ajuste perfecto), sin embargo, autores como Hu y Bentler (1995) consideran que la distribución de estas medidas es desconocida, a excepción obviamente, del test  $\chi^2$ .

Análogamente, aparecen dentro de este grupo de medidas: RMR ("Root Square Residual" o Residuo cuadrático medio) y SRMR ("Standarized Root Mean Square Residual"). Para el primero de estos dos índices, se considera que estamos ante un buen ajuste con valores por debajo de .10, .08, .06 o incluso .04, sin embargo, se trata de un índice difícil de interpretar, por lo que se recomienda utilizar el SRMR en su lugar. Este coeficiente resulta de tomar la raíz cuadrada de la media de los residuos al cuadrado, que se identifica con las cantidades por las que las varianzas y covarianzas de la muestra se diferencian de las correspondientes varianzas y covarianzas estimadas bajo la asunción de que el modelo es correcto. Es decir, el SRMR es la diferencia promedio entre las varianzas y covarianzas predichas y las observadas en el modelo. Por lo tanto, un valor pequeño refleja un buen ajuste. Para un ajuste perfecto este índice debería arrojar un valor de 0, mientras valores por debajo de .05 ya se considera un buen ajuste, y por debajo de .08 un ajuste aceptable, aunque dependiendo de la literatura que consultemos, el límite se sitúa en .10 .

De todos ellos, la única medida de bondad de ajuste con un test de significación asociado es el test  $\chi^2$ , mientras que el resto de medidas e índices son descriptivos. Así, para la evaluación estadística inferencial sólo se dispone del test  $\chi^2$ , que comprueba:  $H_0: S = \Sigma, H_1: S \neq \Sigma$ . Sin embargo, dada la sensibilidad del test  $\chi^2$  al tamaño de muestra (cuestión que se justificará a continuación), resultan de gran utilidad las medidas de naturaleza descriptiva que se acaban de citar, pues también aportan información sobre la bondad del ajuste absoluto del modelo.

Con este test se evalúa si la matriz de covarianzas de la población  $\Sigma$  es igual a la matriz de covarianzas del modelo  $\Sigma(\theta)$ , es decir, bajo la hipótesis nula se trata de verificar que las diferencias entre los elementos de  $\Sigma$  y los elementos de  $\Sigma(\theta)$  son cero:  $\Sigma - \Sigma(\theta) = 0$ .

Es decir, la bondad de ajuste será mayor cuanto menor sea la diferencia entre ambas matrices, de modo que si la diferencia es muy pequeña se podrá entender que el modelo reproduce el comportamiento de los datos observados de un modo razonablemente bueno.

Al tratarse de parámetros poblacionales, estas matrices son desconocidas, por lo que será necesario examinar la matriz de covarianzas empírica  $S$  y la matriz de covarianzas estimada del modelo  $\Sigma(\hat{\theta})$ , donde  $\hat{\theta}$  es un vector ( $t \times 1$ ) de parámetros estimados. Si se verifica la hipótesis nula, el valor mínimo de la función de ajuste  $N - 1$  converge a una  $\chi^2$ .

$$\chi^2(df) = (N - 1)F[S, \Sigma(\hat{\theta})] \quad (11)$$

con  $df = s - t$  grados de libertad, donde:

$s$  es el número de elementos no redundantes en  $S$ ,

$t$  es el número total de parámetros a estimar,

$N$  es el tamaño de muestra,

$S$  es la matriz de covarianzas empírica, y

$\Sigma(\hat{\theta})$  es la matriz de covarianzas estimada

El programa estadístico empleado para la aplicación del modelo que se propone en este trabajo, AMOS, proporciona diferentes valores para el test  $\chi^2$  para los métodos de estimación por máxima verosimilitud, mínimos cuadrados generalizados y estimación por distribución libre asintótica; es decir, el valor del test dependerá del método de estimación que se utilice. En este sentido y, de modo general, se puede decir que valores altos de dicho test en relación al número de grados de libertad indican que la matriz de covarianzas de la población  $\Sigma$  y la matriz de covarianzas del modelo  $\Sigma(\theta)$  son significativamente distintas una de otra.

Por su parte, los residuos (los elementos resultantes de  $S - \Sigma(\hat{\theta})$ ), deben ser nulos o cercanos a cero en un buen ajuste, por lo que se buscará obtener un test  $\chi^2$  no significativo. De este modo, si el p-valor asociado a dicho test es mayor que .05, se aceptará la hipótesis nula y el modelo será compatible con la matriz  $\Sigma$  de covarianzas de la población, en cuyo caso el modelo se ajustaría bien a los datos. En caso contrario, se puede concluir que el modelo propuesto no es consistente con los datos observados.

Sin embargo, ha de tenerse en cuenta la existencia de tres factores que hacen que el test  $\chi^2$  pueda perder eficacia:

- Violación de la condición de normalidad de las variables observadas.
- Complejidad del modelo. Uno de los puntos débiles del estadístico  $\chi^2$  es que su valor decrece cuando incrementan los parámetros del modelo. Es decir, para modelos muy parametrizados y de gran complejidad tiende a producir valores más pequeños de este estadístico en comparación con modelos más sencillos dada la reducción de los grados de libertad empleados.

En otras palabras, cuanta mayor sea la complejidad del modelo, mayor es la probabilidad de que el test acepte el modelo.

Además, no se puede obviar su dependencia del tamaño de muestra. Ante tamaños de muestra pequeños, el test no es capaz de detectar diferencias significativas, aceptando con alta probabilidad modelos que no se ajustan bien a los datos. Por su parte, ante tamaños de muestra grandes, el estadístico tiende a ser estadísticamente significativo, rechazando modelo que en realidad se alejan muy poco de los datos observados.

En definitiva, y en virtud del carácter habitual en la existencia de estos tres factores, a la hora de evaluar la bondad de ajuste de un modelo sería un error evaluarlo únicamente en virtud del nivel de significación del test  $\chi^2$ . Es por ello, por lo que se incorporan diferentes medidas descriptivas que servirán para contrastar el ajuste.

Junto a ellas, se han propuesto otros índices basados en la comparación de la magnitud del estadístico  $\chi^2$  en relación al número de grados de libertad. Esto es, para un buen ajuste se espera que el ratio  $\chi^2/df$  sea lo más pequeño posible. A pesar de que no existe acuerdo sobre niveles estándar, un ratio entre 2 y 3 es indicativo de un "buen" o "aceptable" ajuste del modelo a los datos, respectivamente.

### 3.3.2. Medidas incrementales de ajuste

Nos referimos a ellas como medidas incrementales de ajuste o también como medidas descriptivas basadas en la comparación de modelos.

De forma general, los modelos buscan ser aproximaciones simplificadas de la realidad, buscando explicar un comportamiento observado. Con este fin, se han desarrollado una serie de índices que comparan la mejoría en la bondad de ajuste de

un modelo con la bondad de ajuste de un modelo base<sup>16</sup> (modelo con un ajuste muy pobre). El modelo base más empleado para este tipo de comparaciones es el modelo nulo, en el que se supone que las variables no están relacionadas. Es decir, se busca comparar el modelo propuesto con el peor modelo posible. En este sentido, aunque el ajuste del modelo diseñado no sea perfecto, será una mejor aproximación a la realidad en tanto en cuanto mejore el ajuste del modelo nulo.

De entre esta familia de medidas descriptivas incrementales de ajuste, las más empleadas son: el índice de ajuste normado o "NFI" ("Normed Fit Index"), que mide la reducción proporcional en la función de ajuste cuando se pasa del modelo nulo al propuesto; el índice de ajuste no normado o "NNFI"<sup>17</sup> ("Nonnormed Fit Index"), que compara el ajuste por grado de libertad del modelo propuesto y nulo; el índice de ajuste comparativo o "CFI", ("Comparative Fit Index"), que indica un buen ajuste del modelo para valores próximos a la unidad; el índice de bondad de ajuste ajustado o "AGFI" ("Adjusted Good-ness-of-Fit Index"), que es el GFI ajustado por los grados de libertad del modelo propuesto y del modelo base o nulo; y, el índice de bondad de ajuste ajustado relativo o "RAGFI", que ayuda a evaluar la bondad de ajuste del modelo.

### 3.3.3. Medidas de ajuste de parsimonia

La parsimonia de un modelo es el grado en que alcanza ajuste para cada coeficiente o parámetros estimados, además de funcionar como criterio de selección entre modelos alternativos.

---

<sup>16</sup> El modelo base estipula una falta absoluta de asociación entre las variables del modelo.

<sup>17</sup> El NNFI tiende a 1 para modelos con muy buen ajuste, aunque se consideran aceptables modelos con valores a partir de .09.

Algunos de los índices de parsimonia más utilizados en la estimación de modelos de ecuaciones estructurales son: el índice de bondad de ajuste parsimonioso o "PGFI" ("Parsimony Good-ness-of-Fit Index"), que consiste en el ajuste del GFI basado en la parsimonia del modelo estimado; el índice de ajuste normado parsimonioso o "PNFI"<sup>18</sup> ("Parsimony Normed Fit Index"), que es similar al NFI, pero considerando los grados de libertad usados para alcanzar el nivel de ajuste; el criterio de información de Akaike o "AIC"<sup>19</sup> ("Akaike Information Criterion"), cuya utilidad reside en comparar modelos que poseen diferente número de variables latentes; y, por último, el índice "CAIC" ("Consistent AIC"), que se basa en una transformación del índice anterior.

Pese a que no existe acuerdo sobre cuáles han de ser los valores de todos estos índices y medidas que un buen ajuste debe proporcionar, se presenta a continuación una tabla resumen con las recomendaciones y reglas de decisión más extendidas para la evaluación de este tipo de modelos.

---

<sup>18</sup> Cuando se comparan modelos alternativos, diferencias en sus valores de este índice entre .06 y .09, son muy importantes.

<sup>19</sup> Niveles bajos de este índice, revelan alta parsimonia.



Tabla 1. Resumen de los índices de bondad de ajuste.

Medida de Ajuste	"Buen Ajuste"	"Ajuste Aceptable"
$\chi^2$ p-valor $\chi^2/df$	$0 \leq \chi^2 \leq 2df$ $.05 < p \leq 1.00$ $0 \leq \chi^2/df \leq 2$	$2df \leq \chi^2 \leq 3df$ $.01 \leq p \leq .05$ $2 < \chi^2/df \leq 3$
RMSEA p-valor del test (RMSEA < .05) Interv. de conf. SRMR	$0 \leq RMSEA \leq .05$ $.10 < p \leq 1.00$ próximo a RMSEA límite por la izq. = .00 $0 \leq SRMR \leq .05$	$.05 \leq RMSEA \leq .08$ $.05 \leq p \leq .10$ próximo a RMSEA $.05 < SRMR \leq .10$
NFI NNFI CFI GFI AGFI	$.95 \leq NFI \leq 1.00$ $.97 \leq NNFI \leq 1.00$ $.97 \leq CFI \leq 1.00$ $.95 \leq GFI \leq 1.00$ $.90 \leq AGFI \leq 1.00,$ próximo a GFI	$.90 \leq NFI \leq .95$ $.95 \leq NNFI \leq .97$ $.95 \leq CFI \leq .97$ $.90 \leq GFI \leq .95$ $.85 \leq AGFI \leq .90,$ próximo a GFI
AIC CAIC	AIC más pequeño en la comparación CAIC más pequeño en la comparación	



## CAPÍTULO III

### **Modelización de la satisfacción ciudadana mediante modelos de ecuaciones estructurales. Presentación de resultados**

#### 1. Muestra, descripción y análisis de la base de datos

El estudio se centra en la evaluación del grado de satisfacción de los ciudadanos con determinados servicios prestados en el municipio. La información se ha obtenido a través de realización de una encuesta de satisfacción en uno de los municipios de la provincia de A Coruña que se encuentran dentro de un determinado rango poblacional (ayuntamientos de entre 5.000 a 10.000 habitantes); más concretamente, la población correspondiente al municipio en el que se ha realizado la encuesta es de 5.705 habitantes (dato oficial a 1 de enero de 2010).

La muestra del estudio está conformada por un total de 247 encuestas realizadas a través de CATI a habitantes mayores de edad de este ayuntamiento coruñés. Como resulta habitual, la encuesta se estratificó por cuotas de sexo y edad, dando como resultado que el 47,4% de los encuestados son varones y el 52,6% restante son mujeres. Atendiendo a la distribución por grandes grupos de edad, el 13,8% son menores de 30 años (encuestados con edad comprendida entre los 18 y los 29 años), el 27,9% pertenece al segundo tramo de edad, es decir, entre 30 y 45 años, el 23,9% tienen una edad comprendida entre 45 y 60 años y, por último, el 34,4% restante tienen, al menos, 65 años.

En relación al status o situación laboral en la actualidad, el 43,7% trabaja, el 29% está ya jubilado o es pensionista, el 7,3% está en situación de desempleo, el 4,5% son estudiantes y, el 16,6% restante son amas de casa.

En función del nivel educativo, los sujetos se distribuyen de la siguiente forma: el 0,8% no tiene estudios, el 2% no ha completado los estudios primarios, el 17,4% tienen estudios primarios, el 52,3% tiene, al menos, el bachillerato elemental, y el 27,5% poseen un título universitario.

A continuación se presenta una versión reducida del cuestionario utilizado, que incluye las dimensiones finalmente empleadas en la construcción del modelo de ecuaciones estructurales.

1. Variables para medir la satisfacción global de los ciudadanos:

- $y_3$ : valoración de la administración y los servicios administrativos en una escala de 0 a 10, donde 0 supone la peor valoración y 10 la mejor.
- $y_4$ : grado de satisfacción con los servicios prestados en el municipio, expresado en una escala de 0 a 10, donde 0 supone estar completamente insatisfecho y 10 completamente satisfecho.
- $y_5$ : valoración de la calidad de vida en el municipio, expresada en una escala de 0 a 10.

2. Variables para medir la dimensión de la gestión municipal:

- $y_1$ : valoración de la gestión realizada por el gobierno municipal en una escala de 0 a 10.
- $y_2$ : valoración de la gestión del alcalde en una escala de 0 a 10.

3. Variables para medir la satisfacción de los ciudadanos con el servicio de limpieza y recogida de residuos:
  - $x_1$ : valoración en una escala de 0 a 10 de la frecuencia en la recogida de residuos.
  - $x_2$ : valoración de 0 a 10 del servicio de recogida selectiva de residuos.
  - $x_3$ : valoración de 0 a 10 del número de contenedores para recogida selectiva de residuos.
  - $x_4$ : valoración de 0 a 10 del funcionamiento del servicio de recogida de residuos.
  
4. Variables para medir la satisfacción de los ciudadanos con los servicios sanitarios prestados en el municipio:
  - $x_5$ : valoración, en una escala de 0 a 10, de la distancia al hospital más cercano.
  - $x_6$ : valoración, en una escala de 0 a 10, del número de farmacias en el municipio.
  - $x_7$ : valoración, en una escala de 0 a 10, del número de médicos de atención primaria en el municipio.
  - $x_8$ : valoración, en una escala de 0 a 10, de los centros de salud.
  
5. Variables para medir la satisfacción de los ciudadanos con la red de infraestructuras viarias del municipio:
  - $x_9$ : valoración, en una escala de 0 a 10, de la red de carreteras principales.
  - $x_{10}$ : valoración, en una escala de 0 a 10, de la señalización.
  - $x_{11}$ : valoración, en una escala de 0 a 10, del estado y mantenimiento de las aceras.

- $x_{12}$ : valoración, en una escala de 0 a 10, del estado y pavimentación de las infraestructuras viarias del municipio.
- $x_{13}$ : valoración, en una escala de 0 a 10, del estado de las carreteras secundarias.

Tras haber descrito el contenido de la matriz de datos original, se procede, en primer lugar, al análisis descriptivo de los datos de la encuesta de satisfacción, y posteriormente, se pondrá a prueba el modelo global propuesto, recurriendo al análisis de modelos de ecuaciones estructurales con la aplicación del programa AMOS 16.0, para lo cual se hará uso de diferentes métodos de estimación: máxima verosimilitud, mínimos cuadrados generalizados y distribución libre asintótica (etiqueta bajo la cual se corresponde en el paquete AMOS a la estimación por mínimos cuadrados generalizados).

Tal y como se ha apuntado ya en numerosas ocasiones en este trabajo, la presencia de normalidad multivariada es el primer requisito que cualquier conjunto de datos debería reunir para la aplicación de la mayoría de métodos de estimación de modelos de ecuaciones estructurales. Además, no podemos olvidar otras formas típicas de validar la normalidad de un conjunto de datos. Hablamos, ahora, de asimetría y curtosis.

La matriz de datos original, que recoge las respuestas de 247 individuos, se ha restringido a variables con menos de 10% de casos perdidos. Estos casos faltantes se han reemplazado por la media de la variable correspondiente.

Tabla 2. Valores perdidos.

	N	Recuento	Porcentaje		N	Recuento	Porcentaje
x1	246	1	0,405	x10	244	3	1,215
x2	238	9	3,644	x11	234	13	5,263
x3	246	1	0,405	x12	240	7	2,834
x4	246	1	0,405	x13	242	5	2,024
x5	242	5	2,024	y1	225	22	8,907
x6	243	4	1,619	y2	228	19	7,692
x7	227	20	8,097	y3	223	24	9,717
x8	238	9	3,644	y4	240	7	2,834
x9	247	0	0,000	y5	245	2	0,810

Es importante destacar que han sido pocas las variables observadas que se han descartado para la construcción del modelo inicial a causa de presentar más de un 10% de datos faltantes. Tratar de incorporarlas al modelo supondría un trabajo adicional poco fructífero para el estudio de la satisfacción ciudadana por una razón fundamental: la información que aportan podría solaparse con la que incorporan las 18 variables observadas ya descritas y, como consecuencia de ello, no merecería la pena adentrarse en métodos de imputación que, por otra parte, requeriría un trabajo específico.

La Tabla 3 contiene los principales estadísticos descriptivos de estas 18 variables observadas, que serán las que formen parte del modelo de ecuaciones estructurales con el que se inicia el estudio de la satisfacción ciudadana con los servicios municipales.

Tabla 3. Estadísticos descriptivos. Variables observables.

	N	Media	DT.	Asimetría		Curtosis	
				Coef.	Error típ.	Coef.	Error típ.
x1	247	6,602	2,282	-0,899	0,155	0,693	0,309
x2	247	5,545	2,317	-0,621	0,155	0,203	0,309
x3	247	5,163	2,506	-0,439	0,155	-0,402	0,309
x4	247	6,740	2,036	-0,700	0,155	0,677	0,309
x5	247	5,314	1,986	-0,417	0,155	0,473	0,309
x6	247	7,173	1,550	-0,445	0,155	1,083	0,309
x7	247	5,818	1,985	-0,362	0,155	0,098	0,309
x8	247	5,536	2,093	-0,321	0,155	0,178	0,309
x9	247	4,692	2,535	-0,423	0,155	-0,673	0,309
x10	247	5,045	2,138	-0,609	0,155	0,085	0,309
x11	247	4,181	2,457	-0,344	0,155	-0,754	0,309
x12	247	4,380	2,522	-0,308	0,155	-0,694	0,309
x13	247	3,757	2,352	-0,102	0,155	-0,769	0,309
y1	247	5,960	2,073	-0,688	0,155	0,804	0,309
y2	247	6,383	2,124	-0,652	0,155	0,446	0,309
y3	247	5,976	1,746	-0,873	0,155	1,579	0,309
y4	247	6,192	1,805	-0,554	0,155	0,462	0,309
y5	247	7,232	1,514	-1,102	0,155	3,360	0,309

A la vista de los valores de los estadísticos de la tabla anterior, se entiende que existe normalidad univariada de los datos. Además, ya que conocemos la escala de medición de cada una de ellas, se confirma que la exigencia del nivel de medida<sup>20</sup> de las variables observables se cumple, ya que a pesar de tratarse de variables de intervalo, medidas en una escala de 0 a 10, se tiene una escala lo suficientemente amplia como para poder tratarlas como variables cuantitativas; y dado que el número de valores de cada una de estas variables observables es igual a 11, la probabilidad de que la distribución de los datos se acerque a la normalidad se incrementa considerablemente.

<sup>20</sup> Es necesario que las variables observables o indicatoras sean variables continuas o, excepcionalmente ordinales con al menos 4 niveles.



Otra de las formas típicas de validar la normalidad de un conjunto de datos reside en el estudio y análisis de la curtosis y asimetría que presentan las variables.

En cuanto a la asimetría, valores por encima de  $|3.00|$  indicarían asimetría extrema, mientras que para el caso de la curtosis, valores entre  $|8.00|$  y  $|20.00|$  corroborarían situaciones de curtosis extrema<sup>21</sup>; valores por encima de  $|20.00|$  indicarían un serio problema de normalidad. En consecuencia, los resultados de la Tabla 3 revelan la inexistencia de problemas de asimetría y curtosis en las variables observadas que entrarán a formar parte del modelo de ecuaciones estructurales inicial.

Pero, tal y como ya se ha dicho, resulta condición indispensable la existencia de distribución multivariada de los datos para la aplicación de métodos de estimación como la máxima verosimilitud para modelos de ecuaciones estructurales.

Según Bollen, existe normalidad multivariada cuando el coeficiente de Mardia es inferior a  $p(p + 2)$ , donde  $p$  es el número de variables observadas en el modelo, y el coeficiente de Mardia obtuvo un valor, para el modelo corregido, de 74.325, y en consecuencia podemos afirmar que existe normalidad multivariada de los datos. En consecuencia, resulta pertinente utilizar el método de estimación por máxima verosimilitud en el análisis de la satisfacción ciudadana.

Más allá del estudio de la distribución univariada y multivariada de los datos, también es necesario estudiar las relaciones de correlación que se puedan establecer entre las variables observadas. Para este análisis se incluye en la Tabla 4 la matriz de correlaciones de las variables observadas junto con sus correspondientes medias y desviaciones típicas.

---

<sup>21</sup> Sin embargo, para autores como Bollen y Long (1993), coeficientes de curtosis por debajo de  $|2|$  podrían indicar ausencia de normalidad en la distribución de los datos.

---

Fijándonos en los coeficientes de correlación de Pearson comprobaremos que la existencia de una importante estructura de correlación entre las variables observadas; más concretamente, vemos que las correlaciones son más grandes dentro de cada grupo de variables; es decir, se producen correlaciones más altas entre los ítems de limpieza y recogida de residuos entre sí ( $x_1, \dots, x_4$ ), entre los ítems referentes a la gestión entre sí ( $y_1, y_2$ ), etc. Por tanto, se comprueba la existencia de una estructura de correlación compleja entre las variables observadas, lo cual a su vez hace que sea pertinente pensar en el diseño de un modelo de ecuaciones estructurales para el análisis de la satisfacción ciudadana con estos servicios, en donde además de esta estructura de correlación entre las variables observadas se prevean relaciones directas e indirectas entre los constructos.

Tabla 4. Matriz de correlaciones, medias y desviaciones típicas de las variables observables.

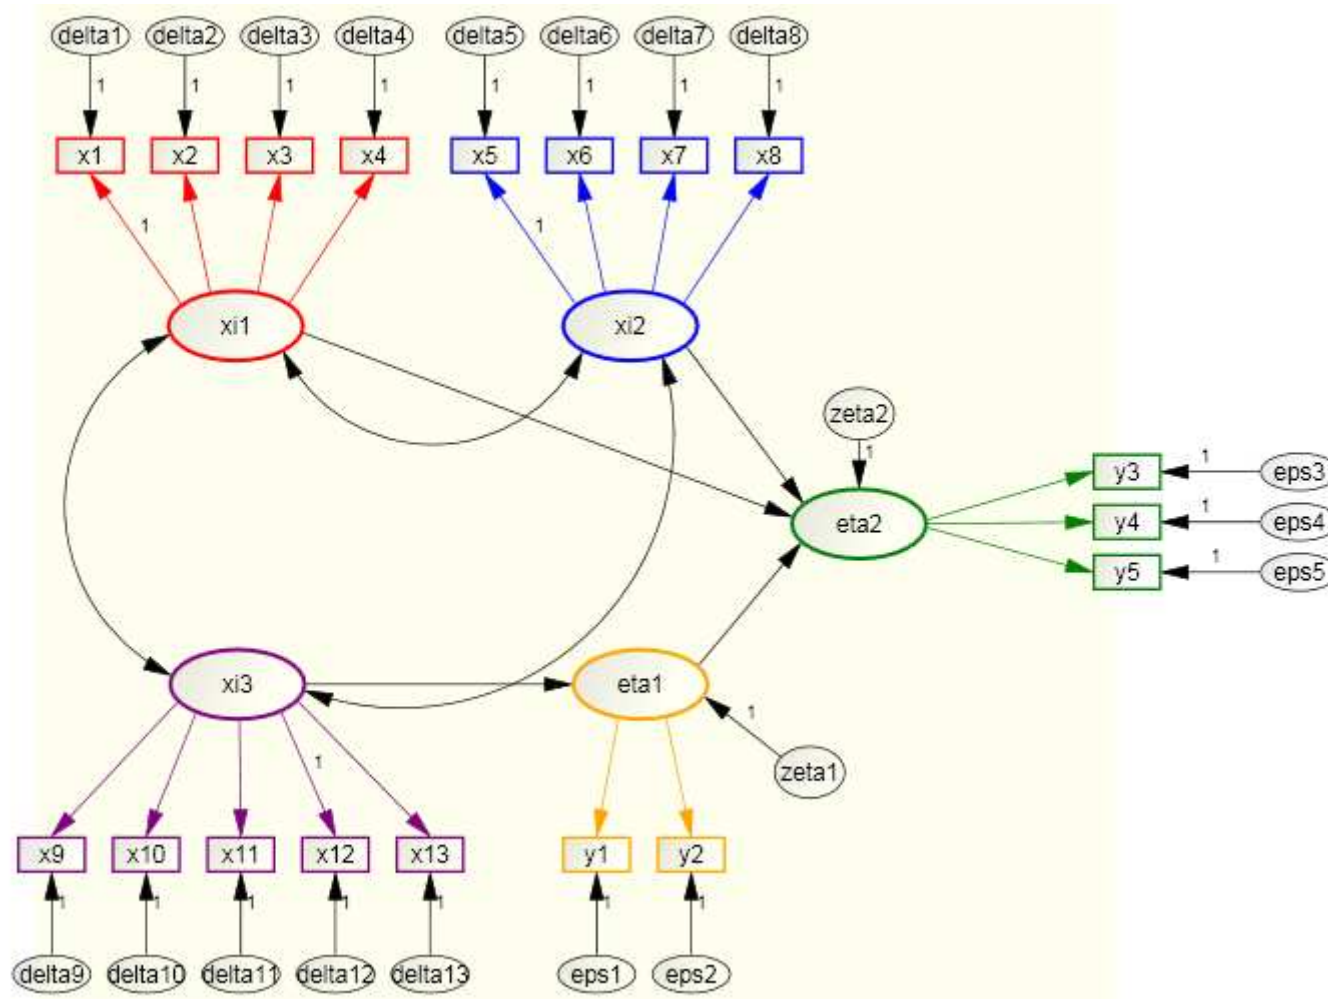
	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	x13	y1	y2	y3	y4	y5
x1	1																	
x2	0,579	1																
x3	0,490	0,759	1															
x4	0,831	0,588	0,470	1														
x5	0,278	-	-	0,230	1													
x6	0,346	0,210	0,213	0,320	0,320	1												
x7	0,262	0,172	0,255	0,268	0,285	0,417	1											
x8	0,268	-	0,183	0,250	0,395	0,395	0,645	1										
x9	0,257	0,182	0,203	0,275	0,239	-	0,290	0,364	1									
x10	0,297	0,315	0,306	0,344	0,235	0,226	0,352	0,375	0,622	1								
x11	0,318	0,234	0,315	0,301	0,251	0,193	0,271	0,343	0,625	0,601	1							
x12	0,292	0,353	0,406	0,355	0,281	0,143	0,326	0,337	0,661	0,630	0,660	1						
x13	0,328	0,277	0,331	0,339	0,218	-	0,293	0,337	0,688	0,625	0,591	0,716	1					
y1	0,444	0,358	0,339	0,423	0,168	0,236	0,210	0,298	0,321	0,391	0,333	0,412	0,386	1				
y2	0,410	0,402	0,356	0,425	0,173	0,261	0,240	0,330	0,262	0,370	0,319	0,391	0,327	0,834	1			
y3	0,382	0,383	0,312	0,434	0,218	0,349	0,380	0,372	0,350	0,483	0,349	0,412	0,377	0,516	0,590	1		
y4	0,491	0,384	0,363	0,455	0,220	0,308	0,268	0,293	0,344	0,396	0,433	0,395	0,381	0,648	0,693	0,553	1	
y5	0,425	0,272	0,211	0,390	0,148	0,290	0,191	0,167	0,233	0,256	0,285	0,276	0,272	0,518	0,475	0,347	0,503	1
μ	6,6016	5,5445	5,1628	6,7397	5,3138	7,1733	5,8178	5,5364	4,6923	5,0445	4,1806	4,3798	3,7571	5,9595	6,3830	5,9757	6,1919	7,2324
DT	2,28192	2,31732	2,50649	2,03561	1,98586	1,54964	1,98531	2,09255	2,53481	2,13803	2,45651	2,52185	2,35181	2,07344	2,12401	1,74591	1,80467	1,51381

En definitiva, tal y como ya se ha apuntado, se presume que en el modelo de ecuaciones estructurales aparezcan 5 variables latentes diferentes.

Uno de los constructos se creará a partir de las 4 variables indicadoras referentes a la satisfacción con el servicio de limpieza y recogida de residuos ( $\xi_1$ ); otro constructo estará definido por las 4 variables referentes a la satisfacción de los ciudadanos con los servicios sanitarios presentados en el ayuntamiento ( $\xi_2$ ); un constructo que busque reflejar el nivel de satisfacción de los ciudadanos con la red de infraestructuras viarias en función de 5 variables indicadoras incluidas en la base de datos ( $\xi_3$ ); un constructo que refleje la satisfacción ciudadana con la gestión realizada en el ayuntamiento, a través de dos variables indicadoras de valoración de la gestión del alcalde y del gobierno municipal ( $\eta_1$ ); por último, la construcción de un constructo que represente el grado de satisfacción global a través de 3 variables indicadoras, referentes a tres dimensiones distintas: por una parte, la valoración de los servicios administrativos, por otra la satisfacción con los servicios prestados en el municipio, y, junto a ellas, la valoración que los ciudadanos hacen de la calidad de vida en el ayuntamiento ( $\eta_1$ ).

El Gráfico 4 nos ayuda a comprender de una forma rápida y sencilla cómo se construyen estas variables latentes a partir de las 18 variables observadas que entran en el modelo de ecuaciones estructurales inicial. Tanto las relaciones de covariación como de regresión entre las variables latentes se analizarán detenidamente en los siguientes puntos; así como también los parámetros a estimar del modelo.

Gráfico 4. Modelo de Ecuaciones Estructurales inicial.



## 2. Fiabilidad de escala. Alpha de Cronbach

Junto al análisis descriptivo es útil y necesario hacer hincapié en la fiabilidad de los datos, para cuyo estudio se analiza el estadístico Alpha de Cronbach. Este estadístico supone un modelo de consistencia interna que estima el límite inferior del coeficiente de fiabilidad basándose en el promedio de las correlaciones entre los ítems, y cuyo cálculo viene determinado por la siguiente expresión:

$$\alpha = \left( \frac{k}{k-1} \right) \left( 1 - \frac{\sum S_i^2}{S_{sum}^2} \right) \quad (12)$$

donde:

$k$  es el número de ítems de la escala o subescala,

$S_i^2$  es la varianza de los ítems (desde 1,...,k) y  $S_{sum}^2$  es la varianza de la escala total. Es decir, este coeficiente mide la fiabilidad de dicha escala (de las variables indicadoras) en función de dos términos: el número de ítems (nº de variables indicadoras) y, la proporción de varianza total de la prueba debida a la covarianza entre sus partes (ítems).

Una de las ventajas que trae consigo la utilización de este estadístico reside en que ofrece la posibilidad de evaluar cuánto mejoraría (o empeoraría) la fiabilidad del índice si se excluyera un determinado ítem.

Tal y como se puede observar en la Tabla 5, los valores de este índice oscilan entre 0.739 y 0.921, alcanzando el 0.919 si tenemos en cuenta la escala total. (Dentro de cada factor, decir cuántos indicadores hay y computar el índice de fiabilidad, además computarlo para todos los indicadores juntos).

Tabla 5. Fiabilidad de escala y consistencia interna. Alpha de Cronbach.

	Nº de Items	Alpha de Cronbach
Xi1	4	0,868
Xi2	4	0,735
Xi3	5	0,908
Eta1	2	0,921
Eta2	3	0,741
Total	18	0,919

Analizando, uno por uno los índices de cada ítem, teniendo en cuenta todas las variables indicadoras, no resulta recomendable eliminar ninguno de ellos con el fin de que el índice de consistencia aumente.

Sin embargo, si nos acercamos al estudio de la consistencia dentro de cada constructo, únicamente en el caso de la satisfacción de los ciudadanos con los servicios sanitarios ofrecidos en el ayuntamiento ( $\xi_2$ ), el coeficiente de Cronbach se incrementa, aunque muy levemente, pasando de 0.735 a 0.742, si eliminamos  $x_5$ <sup>22</sup>.

---

<sup>22</sup> Valoración de la distancia al hospital más cercano.

Tabla 6. Consistencia interna del constructo  $\xi_2$  de Servicios Sanitarios.

	Media de la escala si se elimina el elemento	Varianza de la escala si se elimina el elemento	Correlación elemento-total corregida	Alfa de Cronbach si se elimina el elemento
x5	18,528	21,216	0,410	0,742
x6	16,668	23,163	0,476	0,706
x7	18,023	18,544	0,595	0,633
x8	18,305	17,076	0,648	0,596

### 3. Modelo de Ecuaciones Estructurales Inicial

Tal y como ya se ha expuesto, el modelo de ecuaciones estructurales inicial<sup>23</sup> se construye a partir de 18 variables observadas; variables que se corresponden con 18 ítems de la encuesta de satisfacción realizada en uno de los ayuntamientos de la provincia de A Coruña, perteneciente al grupo de ayuntamientos con población oscila entre 5.000 y 10.000 habitantes.

A partir de ellas se crean 5 variables latentes diferentes a través de análisis factorial confirmatorio. Una vez creadas las variables latentes, se determinan las relaciones que éstas establecen entre sí, pudiendo ser relaciones de correlación y, o, relaciones de regresión.

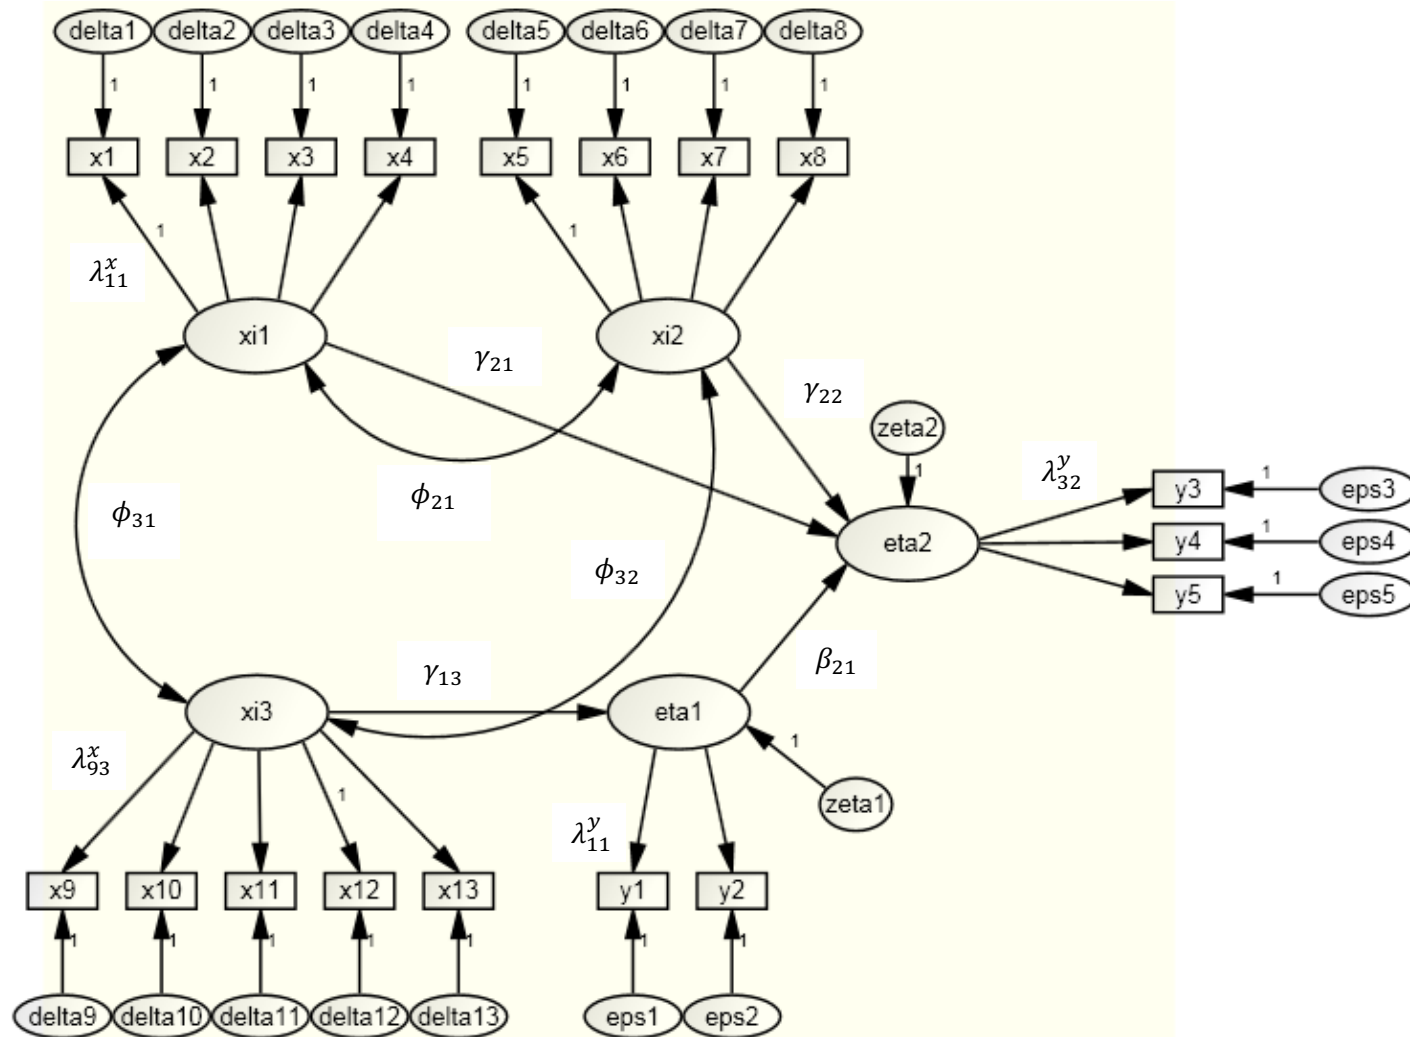
En el Gráfico 5 se pueden apreciar, además de las relaciones que se establecen entre las variables, algunos de los parámetros a estimar del modelo inicial.

---

<sup>23</sup> Al modelo inicial también se le conoce en la literatura sobre ecuaciones estructurales como modelo teórico.



Gráfico 5. Modelo de Ecuaciones Estructurales inicial.



Siguiendo con un análisis más pormenorizado del Gráfico 5, los componentes del modelo de ecuaciones estructurales inicial son los siguientes:

- a. Variables latentes:
  - exógenas  $\xi_1, \xi_2, \xi_3$
  - endógenas  $\eta_1, \eta_2$
- b. Variables observadas:
  - exógenas  $X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8, X_9, X_{10}, X_{11}, X_{12}, X_{13}$
  - endógenas  $Y_1, Y_2, Y_3, Y_4, Y_5$
- c. Errores de medida:
  - de variables observadas exógenas:  
 $\delta_1, \delta_2, \delta_3, \delta_4, \delta_5, \delta_6, \delta_7, \delta_8, \delta_9, \delta_{10}, \delta_{11}, \delta_{12}, \delta_{13}$
  - de variables observadas endógenas:  $\varepsilon_1, \varepsilon_2, \varepsilon_3, \varepsilon_4, \varepsilon_5$
- d. Términos de perturbación:  $\zeta_1, \zeta_2$ , que incluyen los efectos de las variables omitidas, los errores de medida y la aleatoriedad del proceso especificado. La variación en el término de perturbación se denota por  $\psi$  y la covariación entre los términos de perturbación i-ésimo y j-ésimo se denotaría por  $\psi_{ij}$ .
- e. Coeficientes de regresión:  $\lambda_x, \lambda_y$  que relacionan las variables latentes con las observadas.
- f. Coeficientes de regresión:  $\gamma_{13}, \gamma_{21}, \gamma_{22}$ , (representan la relación entre una variable latente exógena y una endógena),  $\beta_{21}$  (relaciona las variables latentes endógenas entre sí) y,  $\phi_{21}, \phi_{31}, \phi_{32}$  (representan la covariación entre las variables latentes exógenas).

Recordemos que los modelos de ecuaciones estructurales están compuestos por el modelo estructural, propiamente dicho y un modelo de medida. Tal y como ya se mencionó en el punto anterior, la representación del modelo estructural sigue la expresión (1):

$$\eta = B\eta + \Gamma\xi + \zeta \quad (13)$$

De forma que la representación del modelo expresado a través de ecuaciones estructurales es:

$$\begin{aligned}\eta_1 &= \gamma_{13}\xi_3 + \zeta_1 \\ \eta_2 &= \beta_{21}\eta_1 + \gamma_{21}\xi_1 + \gamma_{22}\xi_2 + \zeta_2\end{aligned}\tag{14}$$

En formato matricial quedaría expresado del siguiente modo:

$$\begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} = \begin{pmatrix} 0 & 0 \\ \beta_{21} & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} 0 & 0 & \gamma_{13} \\ \gamma_{21} & \gamma_{22} & 0 \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \end{pmatrix} + \begin{pmatrix} \zeta_1 \\ \zeta_2 \end{pmatrix}$$

Por su parte, el modelo de medida quedaría expresado a través de las siguientes ecuaciones:

- Modelo de medida de indicadores endógenos:

$$Y_1 = \lambda_{11}^y \eta_1 + \varepsilon_1$$

$$Y_2 = \lambda_{21}^y \eta_1 + \varepsilon_2$$

$$Y_3 = \lambda_{32}^y \eta_2 + \varepsilon_3$$

$$Y_4 = \lambda_{42}^y \eta_2 + \varepsilon_4$$

$$Y_5 = \lambda_{52}^y \eta_2 + \varepsilon_5$$

- Modelo de medida de indicadores exógenos:

$$X_1 = \lambda_{11}^x \xi_1 + \delta_1$$

$$X_2 = \lambda_{21}^x \xi_1 + \delta_2$$

$$X_3 = \lambda_{31}^x \xi_1 + \delta_3$$

$$X_4 = \lambda_{41}^x \xi_1 + \delta_4$$

$$X_5 = \lambda_{52}^x \xi_2 + \delta_5$$

$$X_6 = \lambda_{62}^x \xi_2 + \delta_6$$

$$X_7 = \lambda_{72}^x \xi_2 + \delta_7$$

$$X_8 = \lambda_{82}^x \xi_2 + \delta_8$$

$$X_9 = \lambda_{93}^x \xi_3 + \delta_9$$

$$X_{10} = \lambda_{103}^x \xi_3 + \delta_{10}$$

$$X_{11} = \lambda_{113}^x \xi_3 + \delta_{11}$$

$$X_{12} = \lambda_{123}^x \xi_3 + \delta_{12}$$

$$X_{13} = \lambda_{133}^x \xi_3 + \delta_{13}$$

Al igual que se ha hecho para el modelo estructural, el modelo de medida expresado de forma matricial es:

- Modelo de medida de indicadores endógenos:

$$\begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \\ Y_5 \end{pmatrix} = \begin{pmatrix} \lambda_{11}^y & 0 \\ \lambda_{21}^y & 0 \\ 0 & \lambda_{32}^y \\ 0 & \lambda_{42}^y \\ 0 & \lambda_{52}^y \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{pmatrix}$$

- Modelo de medida de indicadores exógenos:

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \\ X_7 \\ X_8 \\ X_9 \\ X_{10} \\ X_{11} \\ X_{12} \\ X_{13} \end{pmatrix} = \begin{pmatrix} \lambda_{11}^x & 0 & 0 \\ \lambda_{21}^x & 0 & 0 \\ \lambda_{31}^x & 0 & 0 \\ \lambda_{41}^x & 0 & 0 \\ 0 & \lambda_{52}^x & 0 \\ 0 & \lambda_{62}^x & 0 \\ 0 & \lambda_{72}^x & 0 \\ 0 & \lambda_{82}^x & 0 \\ 0 & 0 & \lambda_{93}^x \\ 0 & 0 & \lambda_{103}^x \\ 0 & 0 & \lambda_{113}^x \\ 0 & 0 & \lambda_{133}^x \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \end{pmatrix} + \begin{pmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \delta_7 \\ \delta_8 \\ \delta_9 \\ \delta_{10} \\ \delta_{11} \\ \delta_{12} \\ \delta_{13} \end{pmatrix}$$

#### 4. Identificación del modelo inicial

Para el modelo representado en el gráfico anterior, el número total de variables endógenas es  $p=5$ , variables exógenas  $q=13$ , por lo que  $s=18$ ; en virtud de lo cual, el número de elementos no redundantes en  $\Sigma$  es de 171. En este caso, el número total de parámetros del modelo a ser estimados, denotados por  $t$ , asciende a 44.

Es decir, dado que  $t$  es estrictamente menor que  $\frac{1}{2} s(s+1)$ , podemos afirmar que el modelo se encuentra sobre-identificado, por lo que el modelo cumple la condición necesaria para estar identificado. Además, es importante señalar que estamos ante un modelo recursivo, puesto que no existe ninguna correlación entre residuos.

#### 5. Estimación y ajuste. Presentación de resultados

Antes de presentar los ajustes obtenidos, hay que decir que, en un paso previo, se examinaron los resultados buscando posibles estimaciones infractoras, o lo que es lo mismo, coeficientes estimados tanto en los modelos de medida como en los estructurales que excedan los límites aceptables. Esto es:

- Varianzas de error negativas o varianzas de error no significativas para cualquiera de los 5 constructos.
- Coeficientes estandarizados cuyos valores sobrepasen 1.000.
- Errores estándar muy elevados asociados con cualquier coeficiente estimado.

Sin embargo, en el planteamiento del modelo inicial, no se encontró ninguna de estas estimaciones infractoras, por lo que no ha sido necesario aplicar ninguna medida correctiva, puesto que todas las estimaciones resultaron estadísticamente significativas y confiables.

Así pues, llegado este punto, es oportuno comenzar, en primer lugar, por estudiar y analizar el modelo inicial (Modelo 1 de aquí en adelante) estimado por máxima verosimilitud, por no violarse la condición de normalidad multivariada y ser el método más recomendado por la mayoría de los autores consultados.

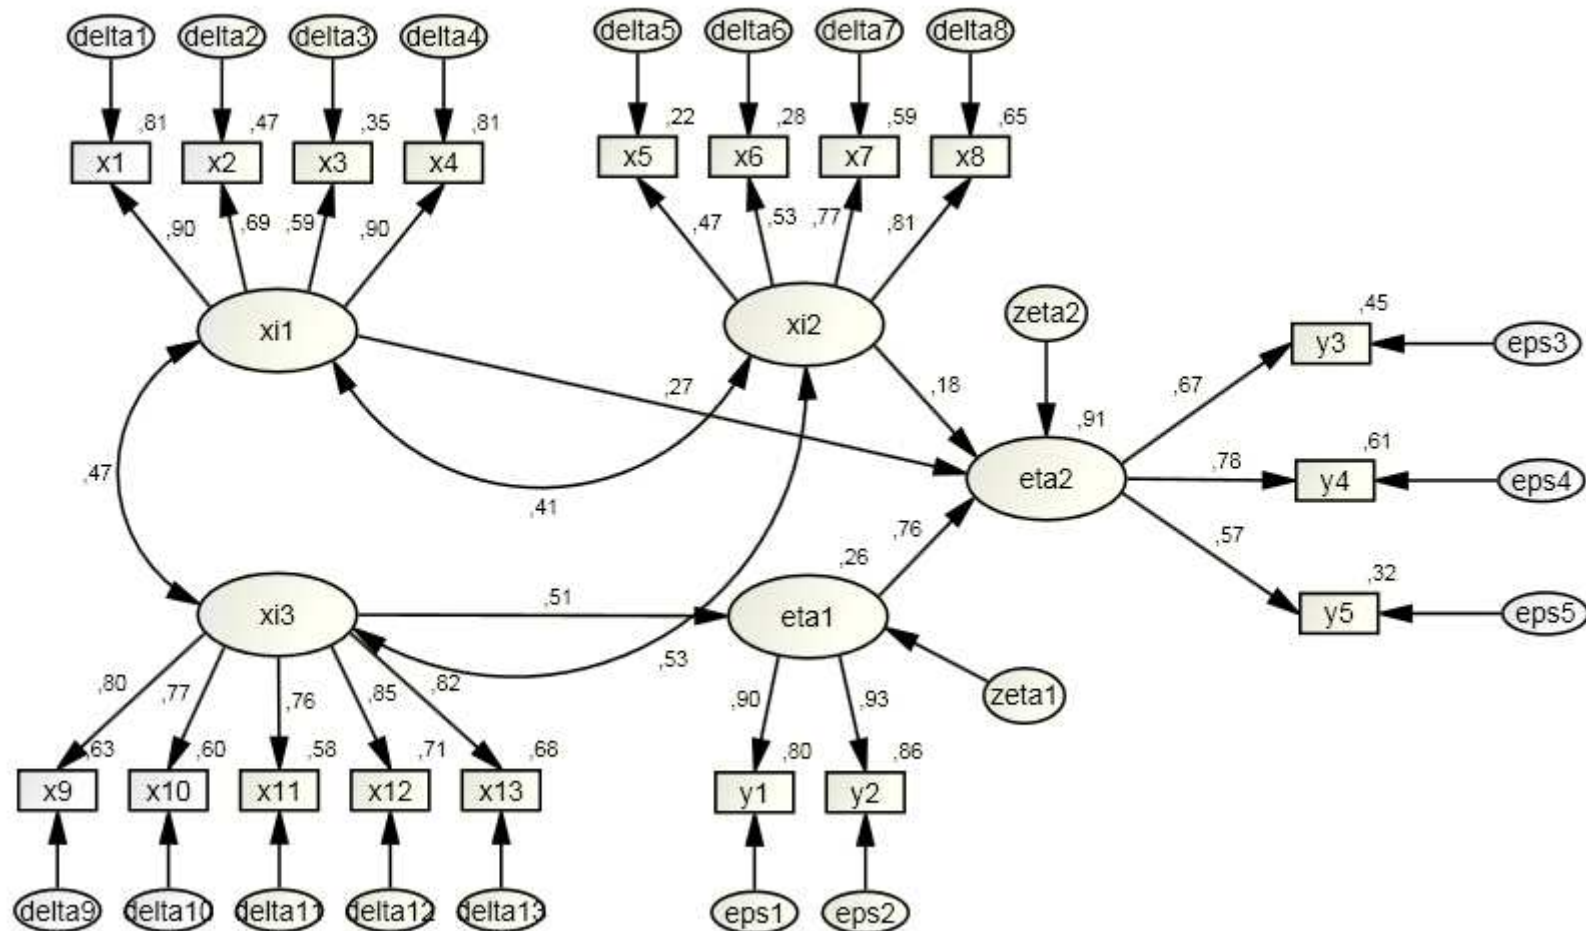
En suma, el Modelo 1 representado en el Gráfico 6, está integrado por un total de 43 variables, de las cuales 23 son variables exógenas y 20 variables endógenas; aparecen 18 variables directamente observables, también llamadas indicadoras, representadas a través de rectángulos. Junto a ellas aparecen asociados los errores de medida y los 5 constructos, o variables latentes (variables no observadas directamente) representadas mediante elipses.

En el gráfico aparecen las estimaciones de todos los parámetros del modelo; estimaciones que están estandarizadas<sup>24</sup> para que la interpretación del modelo sea más sencilla.

---

<sup>24</sup> El programa AMOS proporciona las estimaciones de los parámetros tanto estandarizadas como no estandarizadas.

Gráfico 6. Modelo 1 de Ecuaciones Estructurales. Estimación por Máxima Verosimilitud (estimaciones estandarizadas).



En primer lugar, corresponde analizar el ajuste del modelo de medida, así como las relaciones entre las distintas variables que conforman el Modelo 1, partiendo de los distintos parámetros, estimados por máxima verosimilitud, que aparecen reflejados en el Gráfico 6.

Los valores que aparecen junto a las flechas que van desde los constructos a las variables de medida indican la "carga factorial" de las variables indicadoras o directamente observables en el factor común. Por su parte, en la parte superior de los rectángulos que representan a las variables indicadoras encontramos el valor de la varianza explicada en la variable por el constructo ( $R^2$ ), que podemos entender como la fiabilidad de la medida.

Tabla 7.  $R^2$

Estimate		Estimate	
eta1	0,258	x12	0,715
eta2	0,907	x13	0,678
y5	0,32	x8	0,653
y4	0,611	x7	0,593
y3	0,448	x6	0,284
y1	0,801	x5	0,221
y2	0,864	x4	0,809
x9	0,635	x3	0,352
x10	0,595	x2	0,471
x11	0,583	x1	0,811

Las cargas factoriales del Modelo 1 estimado por máxima verosimilitud, representado en el Gráfico 4, oscilan entre .47 y .93, con unos índices de fiabilidad aceptables, en la mayoría de los casos. Uno de los constructos mejor definidos es  $\xi_3$ , que representa la satisfacción de los ciudadanos con la red de infraestructuras viarias en el municipio.

---



Las correlaciones entre los constructos (representadas mediante flechas bidireccionales) son moderadas, entre las cuales destaca la correlación entre  $\xi_3$  y  $\xi_2$ , o lo que es lo mismo, entre el constructo que representa la satisfacción con la red de infraestructuras viarias y el constructo que representa la satisfacción con los servicios sanitarios prestados en el municipio, con un valor de .53; mientras que la correlación más baja se da entre  $\xi_1$  y  $\xi_2$  (entre el constructo que representa el servicio de limpieza y recogida de residuos y el que representa los servicios sanitarios ofrecidos en el municipio), con un valor de .41.

El siguiente paso en el análisis de ajuste del modelo comienza comprobando que el Modelo 1 se confirma, es decir, llevando a cabo la evaluación global del mismo, de forma que se pueda determinar en qué medida este modelo inicial reproduce adecuadamente las relaciones que existen en la matriz de covarianzas de los datos empíricos. En la Tabla 8 se muestran los índices para analizar plausibilidad de dicho modelo. Con 128 grados de libertad y un valor de Chi Cuadrado de 372,654 tenemos un estadístico con una probabilidad asociada menor de .000, por lo que aunque este estadístico tiene un valor significativo, dado que la variable no es "estrictamente" continua, el valor de Chi Cuadrado está sobrestimado y por esto prestamos atención al resto de los valores de los índices de ajuste.

Sin embargo, hay que decir que, considerándolo de forma aislada, al .05% de confianza, se considera que existen diferencias significativas entre el modelo estimado y los datos, por lo que, sin tener en cuenta ningún otro tipo de medida, provisionalmente se asumiría que el modelo no se ajusta a los datos, aunque, al hilo de lo que ya se ha expuesto en alguna ocasión en este trabajo, es necesario contextualizar el valor de este estadístico con otros criterios de bondad de ajuste que se presentarán más adelante.

Tabla 8. Resumen del Modelo 1. Estimación por Máxima Verosimilitud

Modelo 1	NPAR	Chi-square	DF	P	Chi-square/DF
Default model	61	372,654	128	0,000	2,911
Saturated model	189	0,000	0		
Independence model	36	2680,118	153	0,000	17,517

Además, los resultados del chi-cuadrado también quedan mediatizados por el  $n$  de la muestra (247), que cuanto más grande es, peor es el ajuste y se incrementa la posibilidad de rechazar el modelo, aunque las diferencias entre las matrices observada y reproducida sean mínimas. Es importante señalar que esta argumentación habrá que mantenerla para todos los distintos modelos que se presentan en este trabajo de investigación.

La siguiente tabla, Tabla 9, contiene las estimaciones de los parámetros del modelo (Modelo 1-ML), el error estándar aproximado (S.E.), la proporción crítica (C.R.) y las estimaciones estandarizadas de los parámetros.

La proporción crítica (C.R.) es el cociente entre la estimación del parámetro y la estimación del error estándar. Si se reúnen las suposiciones de distribución apropiadas, este estadístico sigue una distribución normal estándar bajo la hipótesis nula de que el parámetro tiene un valor de cero. Es decir, si a una estimación le corresponde una proporción crítica mayor que 2 en valor absoluto, más concretamente 1.96, el parámetro es significativamente diferente de cero al nivel .05.

A la vista de los resultados contenidos en dicha tabla, se comprueba que todos los valores de proporción crítica son mayores que dos, por lo que en consecuencia, todos los parámetros estimados son significativos.

Como ejemplo se interpreta el primer parámetro que aparece en la tabla, 0.518, es el valor con el cual la variable latente exógena  $\xi_3$  ( $x_{i3}$ ) influye sobre la variable latente endógena  $\eta_1$  ( $\eta_{1}$ ).

Tabla 9. Estimaciones de Máxima Verosimilitud del Modelo 1.

			Estimate	S.E.	C.R.	S. Estimate	Sig.
eta1	<---	$x_{i3}$	0,518	0,068	7,619	0,508	0,000
eta2	<---	eta1	0,440	0,043	10,216	0,764	0,000
eta2	<---	$x_{i2}$	0,221	0,083	2,669	0,181	0,008
eta2	<---	$x_{i1}$	0,152	0,034	4,459	0,275	0,000
$x_1$	<---	$x_{i1}$	1,000			0,901	0,000
$x_2$	<---	$x_{i1}$	0,774	0,064	12,103	0,686	0,000
$x_3$	<---	$x_{i1}$	0,723	0,073	9,858	0,593	0,000
$x_4$	<---	$x_{i1}$	0,891	0,044	20,071	0,899	0,000
$x_5$	<---	$x_{i2}$	1,000			0,470	0,000
$x_6$	<---	$x_{i2}$	0,886	0,155	5,701	0,533	0,000
$x_7$	<---	$x_{i2}$	1,640	0,254	6,444	0,770	0,000
$x_8$	<---	$x_{i2}$	1,813	0,269	6,742	0,808	0,000
$x_{13}$	<---	$x_{i3}$	1,000			0,824	0,000
$x_{12}$	<---	$x_{i3}$	1,101	0,071	15,540	0,845	0,000
$x_{11}$	<---	$x_{i3}$	0,968	0,073	13,225	0,763	0,000
$x_{10}$	<---	$x_{i3}$	0,852	0,063	13,516	0,772	0,000
$x_9$	<---	$x_{i3}$	1,043	0,073	14,336	0,797	0,000
$y_2$	<---	eta1	1,000			0,930	0,000
$y_1$	<---	eta1	0,940	0,048	19,594	0,895	0,000
$y_3$	<---	eta2	1,000			0,669	0,000
$y_4$	<---	eta2	1,196	0,107	11,191	0,782	0,000
$y_5$	<---	eta2	0,739	0,088	8,407	0,566	0,000

De este modo, los modelos de medida y estructural quedan definidos a través de las siguientes ecuaciones:

$$\begin{array}{ll}
 \eta_1 = 0.518 * \xi_3 & x_8 = 1.813 * \xi_2 \\
 \eta_2 = 0.440 * \eta_1 & x_{13} = 1.000 * \xi_3 \\
 \eta_2 = 0.221 * \xi_2 & x_{12} = 1.101 * \xi_3 \\
 \eta_2 = 0.152 * \xi_1 & x_{11} = 0.698 * \xi_3 \\
 x_1 = 1.000 * \xi_1 & x_{10} = 0.852 * \xi_3 \\
 x_2 = 0.774 * \xi_1 & x_9 = 1.043 * \xi_3 \\
 x_3 = 0.723 * \xi_1 & y_2 = 1.000 * \eta_1 \\
 x_4 = 0.891 * \xi_1 & y_1 = 0.940 * \eta_1 \\
 x_5 = 1.000 * \xi_2 & y_3 = 1.000 * \eta_2 \\
 x_6 = 0.886 * \xi_2 & y_4 = 1.196 * \eta_2 \\
 x_7 = 1.640 * \xi_2 & y_5 = 0.739 * \eta_2
 \end{array}$$

A continuación se presenta en la Tabla 10, el mínimo valor de la función de discrepancia (FMIN), igual a 1.515 del modelo. Al respecto de la función de discrepancia, Bentler y Bonett (1980) y Tucker y Lewis (1973) sugieren ajustar el modelo de independencia o algún otro modelo básico o nulo, para ver cuán grande puede llegar a ser la función de discrepancia. Como se puede observar en la tabla 9, el Modelo 1 tiene un valor de discrepancia de 1.515, que es un valor razonable comparado con 10.895, valor de la función de discrepancia correspondiente al modelo de independencia. Es muy habitual utilizar este modelo de independencia como modelo básico, y es el modelo que utiliza el programa AMOS. Por el contrario, el modelo saturado se corresponde con aquél que alcanza un ajuste perfecto.

Tabla 10. Función de discrepancia. Resumen de los modelos.

Modelo 1	FMIN	LO 90	HI 90
Default model	1,515	0,775	1,245
Saturated model	0,000	0,000	0,000
Independence model	10,895	9,605	10,970

El tercer paso en el análisis de nuestro modelo pasa por la evaluación de los índices de bondad ajuste global, evaluando el modelo estructural y de medida conjuntamente, esto es, sin que sea necesario el análisis de ambos por separado. De este modo, se comprobará si, en efecto, los datos se ajustan al modelo propuesto.

Tabla 11. Medidas de ajuste global del Modelo 1. Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
GFI	0,861	1,000	-
NCP	244,654	0,000	2527,118
LO 90	190,635	0,000	2362,877
HI 90	306,313	0,000	2698,710
RMSEA	0,088	-	0,259
LO 90	0,078	-	0,251
HI 90	0,099	-	0,268
SRMR	0,083	-	-
PCLOSE	0,000	-	0,000

En relación a los índices absolutos de ajuste, el modelo inicial propuesto, presenta, de forma general, un ajuste pobre, ya que se tienen valores de GFI, RMSEA fuera de los límites de aceptación establecidos, resumidos en la Tabla 11. Si bien es cierto, que los valores de ninguno de ellos se aleja mucho de estos límites, pues la raíz cuadrada del error cuadrático medio (RMSEA) toma un valor de .088, el límite para un ajuste aceptable se sitúa .08 y, por su parte, el GFI que toma un valor de .861, cercano al límite del .90 establecido como límite inferior para poder calificar como aceptable un modelo.

El valor del estadístico ji-cuadrado no centrado, *NCP*, no es cercano a cero, lo que implicaría que existen diferencias entre la matriz de observaciones y la matriz estimada, sin embargo, si lo comparamos con el valor que toma este mismo estadístico para el modelo nulo, se comprueba que el modelo propuesto presenta un valor mucho más bajo, lo cual es un buen indicativo de este índice. Es posible estandarizar este índice o parámetro de no centralidad, dividiendo por el tamaño de muestra, con lo que se obtendría lo que se conoce como Parámetro de No Centralidad a Escala (*SNCP*), así:

$$SNCP = (\chi^2 - df)/N = \frac{244.645}{247} = 0.99$$

Esta medida ajustada es análoga a la medida de la distancia media euclídea al cuadrado entre el modelo estimado y el modelo sin restricción. El objetivo es minimizar el valor de este parámetro y, dado que no existe ningún test estadístico para esta medida, resulta de utilidad para comparar entre modelos alternativos.

Además, la estandarización del valor del residuo cuadrático medio (*SRMR*) arroja un resultado de 0.083; un valor que se encuentra dentro de los límites para considerar el ajuste del modelo "aceptable".

Otro tipo de índices de ajuste del modelo, de los que ya hemos hablado, son los índices incrementales de ajuste, tradicionalmente promovidos por Bentler (en el programa EQS). Este tipo de índices comparan el modelo implementado, en este caso, el Modelo 1, con el modelo base o nulo, en el que se asume que las covarianzas entre las variables son cero.

La siguiente tabla (Tabla 12) contiene los valores de algunos de los índices incrementales de ajuste que habitualmente se utilizan. En ella se puede verificar que solamente dos de ellos, el índice incremental de ajuste, o IFI, y el índice comparativo de ajuste , CFI<sup>25</sup>, están por encima del límite establecido como el valor mínimo necesario para catalogar a un modelo como aceptable en su ajuste a los datos, .90. Es decir, todo ello apunta hacia un ajuste pobre del modelo, pese a que en alguno de los índices hasta ahora presentados, se pueda considerar como aceptable.

Tabla 12. Medidas incrementales de ajuste del Modelo 1. Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
NFI	0,861	1,000	0,000
RFI	0,834		0,000
IFI	0,904	1,000	0,000
TLI	0,884		0,000
CFI	0,903	1,000	0,000
AGFI	0,884		0,000

Hay que decir que tanto el NFI, como IFI, RFI y TLI, son medidas e índices que comparan el modelo estimado (Modelo 1) con un modelo base que tradicionalmente suele ser aquel que estipula la falta total de asociación entre las variables del modelo; en otras palabras, comparan el modelo estimado con el peor modelo posible.

Para finalizar con el análisis de los índices de ajuste del modelo, resta presentar e interpretar los índices de parsimonia, que ofrecen medidas del ajuste del modelo por coeficiente estimado. Se presentan, a continuación, los valores de todos los índices de parsimonia que ofrece la salida de resultados del programa AMOS. (Ver Tabla 13).

<sup>25</sup> Delos índices incrementales de ajuste éste, CFI, es el más recomendado por Bentler y cuyo valor oscila entre 0 y 1. Aporta información sobre la pérdida relativa de ajuste del modelo en cuestión, versus, la pérdida de ajuste del modelo base o nulo.

Tabla 13. Medidas de ajuste de parsimonia del Modelo 1. Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
PNFI	0,756	0,000	0,000
PGFI	0.702	-	-
AIC	494,654	378,000	2752,118
BCC	504,865	409,639	2758,145
HOELTER 0.5	103	-	17,000
HOELTER 0.1	111,000	-	19,000

En definitiva, con los tests o índices de bondad de ajuste que aquí se han presentado, lo que se busca es determinar hasta qué punto las diferencias obtenidas entre la matriz de varianzas y covarianzas muestral y la matriz de varianzas y covarianzas estimada a partir de este Modelo 1 inicial, son debidas al azar o a que el modelo es falso.

Para completar el análisis, las estimaciones de los parámetros correspondientes al Modelo 1 se han calculado, también, empleando otros métodos de estimación ampliamente extendidos en la aplicación de modelos de ecuaciones estructurales y de los que ya se ha hablado en este trabajo: el método de mínimos cuadrados generalizados y el método de distribución libre asintótica.

Se presentan los resultados de los índices de ajuste global del Modelo 1 en sendas tablas resumen, de modo que se pueda hacer una comparación rápida y sencilla de los valores arrojados por los diferentes métodos de estimación empleados; máxima verosimilitud (ML), mínimos cuadrados generalizados (GLS) y distribución libre asintótica (ADF) y, a continuación, los gráficos con las estimaciones estandarizadas del Modelo 1 estimadas por GLS y ADF. (ver Gráfico 7 y Gráfico 8).



Tabla 14. Comparativa resumen del Modelo1. Tres métodos de estimación.

Modelo 1	ML					GLS					ADF				
	NPAR	Chi-square	DF	P	Chi-square/DF	NPAR	Chi-square	DF	P	Chi-square/DF	NPAR	Chi-square	DF	P	Chi-square/DF
Default model	61	372,654	128	0,000	2,911	43	249,559	128	0,000	1,950	43	507,383	128	0,000	3,964
Saturated model	189	0,000	0	-	-	171	0,000	0	-	-	171	0,000	0	-	-
Independence model	36	2680,118	153	0,000	17,517	18	540,251	153	0,000	3,531	18	1569,630	153	0,000	10,259

Tabla 15. Comparativa de la función de discrepancia. Tres métodos de estimación.

Modelo 1	ML			GLS			ADF		
	FMIN	LO 90	HI 90	FMIN	LO 90	HI 90	FMIN	LO 90	HI 90
Default model	1,515	0,775	1,245	1,014	0,328	0,692	2,063	1,276	1,838
Saturated model	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
Independence model	10,895	9,605	10,970	2,196	1,301	1,878	6,381	5,257	6,291

Tabla 16. Comparativa de las medidas de ajuste global del Modelo 1. Tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
GFI	0,861	1,000		0,887	1,000	0,756	0,845	1,000	0,522
NCP	244,654	0,000	2527,118	121,559	0,000	387,251	379,383	0,000	1416,630
LO 90	190,635	0,000	2362,877	80,596	0,000	320,162	313,854	0,000	1293,177
HI 90	306,313	0,000	2698,710	170,320	0,000	461,927	452,475	0,000	1547,499
RMSEA	0,088	-	0,259	0,062	-	0,101	0,11	-	0,194
LO 90	0,078	-	0,251	0,051	-	0,920	0,100	-	0,185
HI 90	0,099	-	0,268	0,074	-	0,111	0,12	-	0,203
SRMR	0,083	-	-	0,089	-	-	-	-	-
PCLOSE	0,000	-	0,000	0,042	-	0,000	0,000	-	0,000

Tabla 17. Comparativa de las medidas incrementales de ajuste global del Modelo 1. Tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
NFI	0,861	1,000	0,000	0,538	1,000	0,000	0,845	1,000	0,000
RFI	0,834	-	0,000	0,448	-	0,000	0,614	-	0,000
IFI	0,904	1,000	0,000	0,705	1,000	0,000	0,737	1,000	0,000
TLI	0,884	-	0,000	0,625	-	0,000	0,680	-	0,000
CFI	0,903	1,000	0,000	0,686	1,000	0,000	0,732	1,000	0,000
AGFI	0,884	-	-	0,849	-	0,727	0,793	-	0,465

Tabla 18. Comparativa de las medidas de ajuste de parsimonia del Modelo 1. Tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
PNFI	0,756	0,000	0,000	0,45	0,000	0,000	0,566	0,000	0,000
PGFI	0,702	-	-	0,664	-	0,676	0,613	0,000	0,000
AIC	494,654	378,000	2752,118	335,559	342,000	576,251	593,383	342,000	1605,630
BCC	504,865	409,639	2758,145	529,463	1113,105	657,42	787,287	1113,105	1686,799
HOELTER 0.5 index	103	-	17	154	84	23	76	-	29
HOELTER 0.1 index	111	-	19	166	90	25	82	-	31

Gráfico 7. Modelo 1 de Ecuaciones Estructurales. Estimación por Mínimos Cuadrados Generalizados (estimaciones estandarizadas).

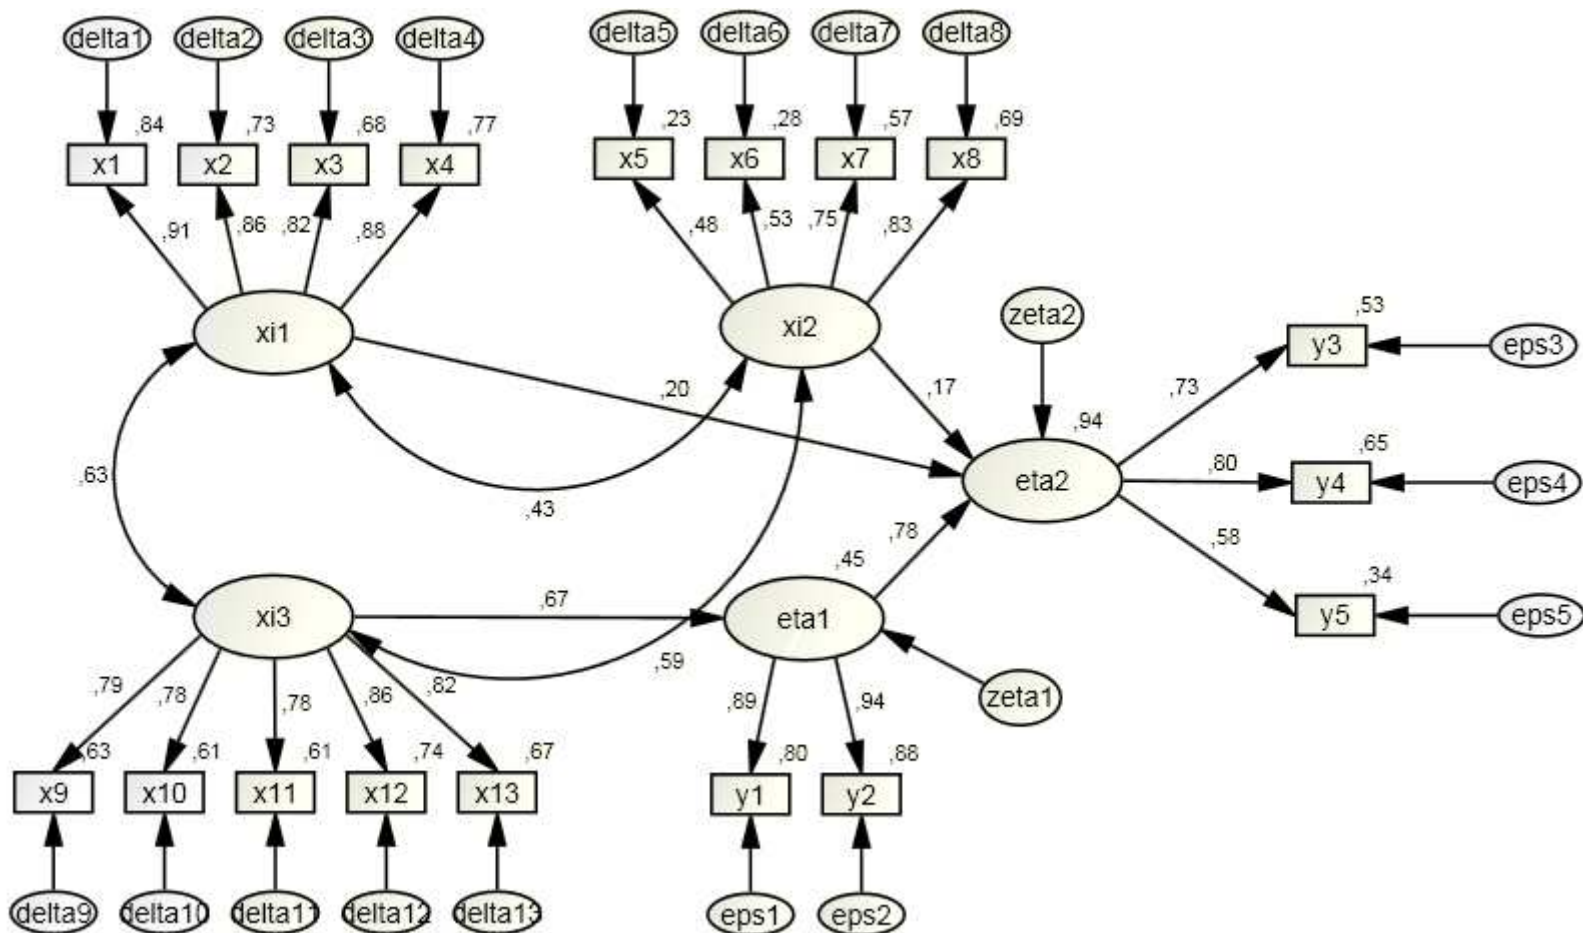
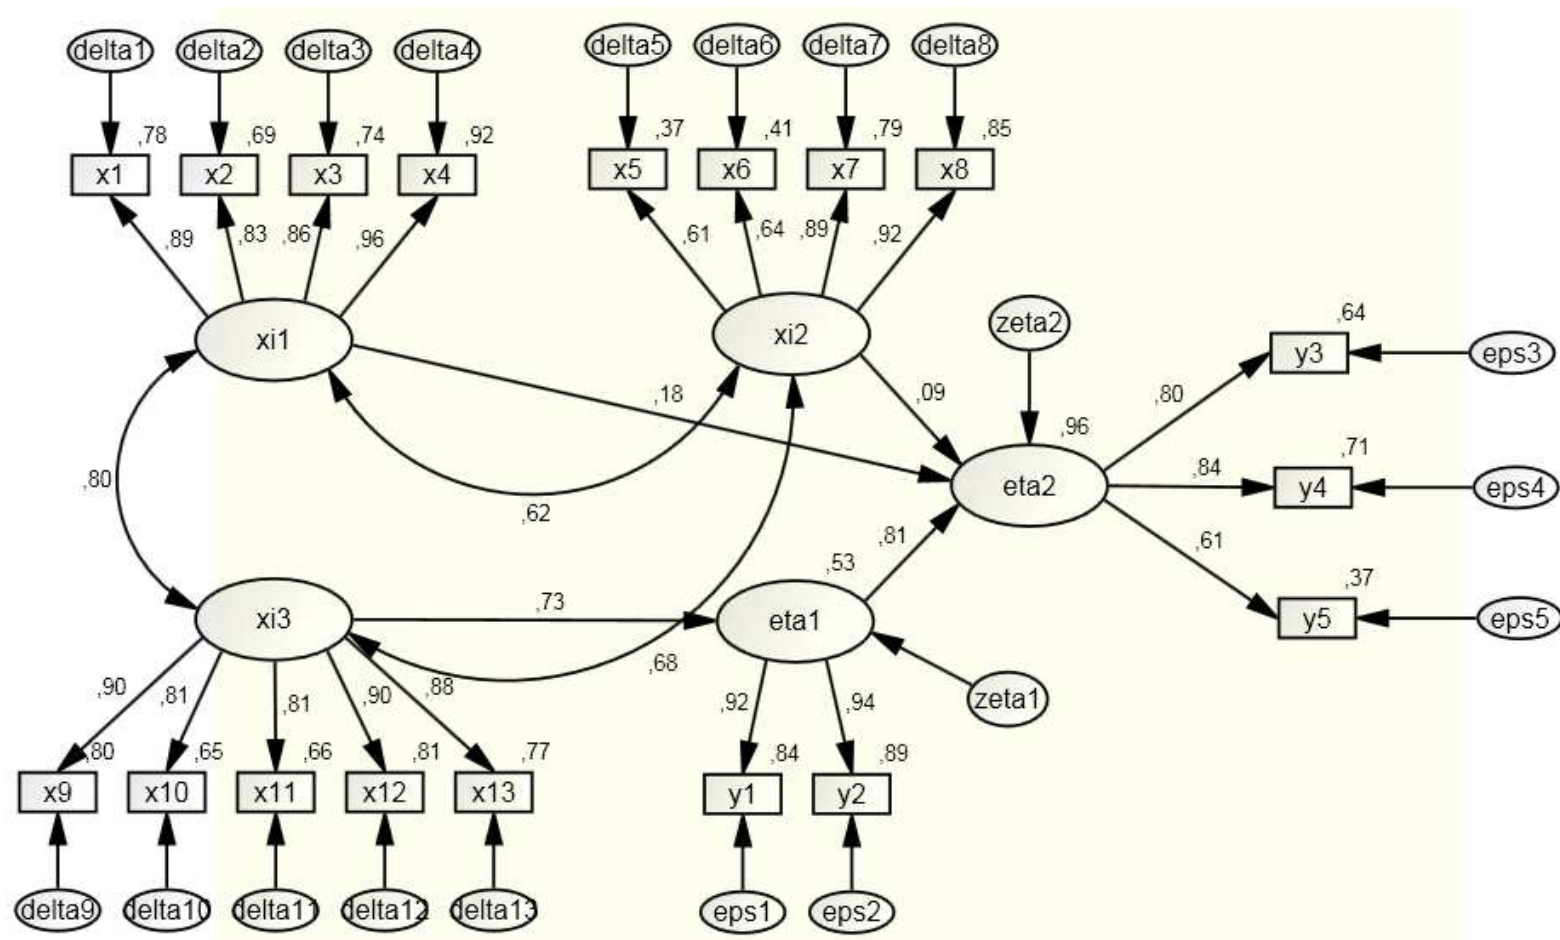


Gráfico 8. Modelo 1 de Ecuaciones Estructurales. Estimación por Distribución Libre Asintótica (estimaciones estandarizadas).



En las Tablas 14 a 18 anteriores, de utilidad para comparar entre los tres métodos de estimación del Modelo 1, se presenta también el índice de validación cruzada esperada o ECVI, que supone una aproximación a la bondad de ajuste que alcanzaría el modelo estimado en otra muestra del mismo tamaño, teniendo en cuenta el número de parámetros estimados tanto para el modelo de medida como para el modelo estructural. Para su cálculo, se divide valor del estadístico  $\chi^2$  del modelo estimado entre el tamaño de muestra menos 1, más dos veces el número de parámetros estimados entre el tamaño de muestra menos 1.

Asimismo, también se incluyen los valores correspondientes al índice de Hoelter, medida empleada para juzgar si el tamaño de muestra es adecuado. Por consenso, se considera que éste resulta adecuado cuando N de Hoelter es mayor que 200, mientras que valores por debajo de 75 se consideran inaceptables. Esta medida es de utilidad para entender el "gap" entre el ajuste y la sensibilidad del valor del estadístico  $\chi^2$  respecto del tamaño de muestra.

Como se ha visto, son muchos los índices de ajuste que presentados para la evaluación del ajuste de este modelo y que programas de estimación de modelos de ecuaciones estructurales, como AMOS y LISREL entre otros, proporcionan. Sin embargo, hay que señalar que ninguno de ellos por separado resulta suficiente para determinar si el modelo se ajusta debidamente a los datos. En la actualidad, la combinación más extendida y utilizada es la siguiente:  $\chi^2$ , RMSEA, ECVI, SRMR, GFI y CFI; ya que el análisis e interpretación de este conjunto de índices resulta suficiente como para poder tomar una decisión en cuanto al ajuste del modelo en cuestión.

En virtud de lo expuesto hasta ahora, y en virtud de los valores que han tomado estas medidas de ajuste, podemos deducir que el modelo presenta capacidad de mejora, por lo que resulta necesario realizar las modificaciones pertinentes.

Con ello, se espera que, tras la estimación de un modelo "corregido", los valores de los índices de bondad de ajuste sean mejores y más favorables. Así, con este nuevo objetivo, se considera procedente y oportuna la eliminación de determinados ítems del Modelo 1; más concretamente, de  $\gamma_5$ ,  $x_2$ ,  $x_3$ ,  $x_5$  y  $x_6$ . El prescindir de estos ítems queda justificado por varias razones:

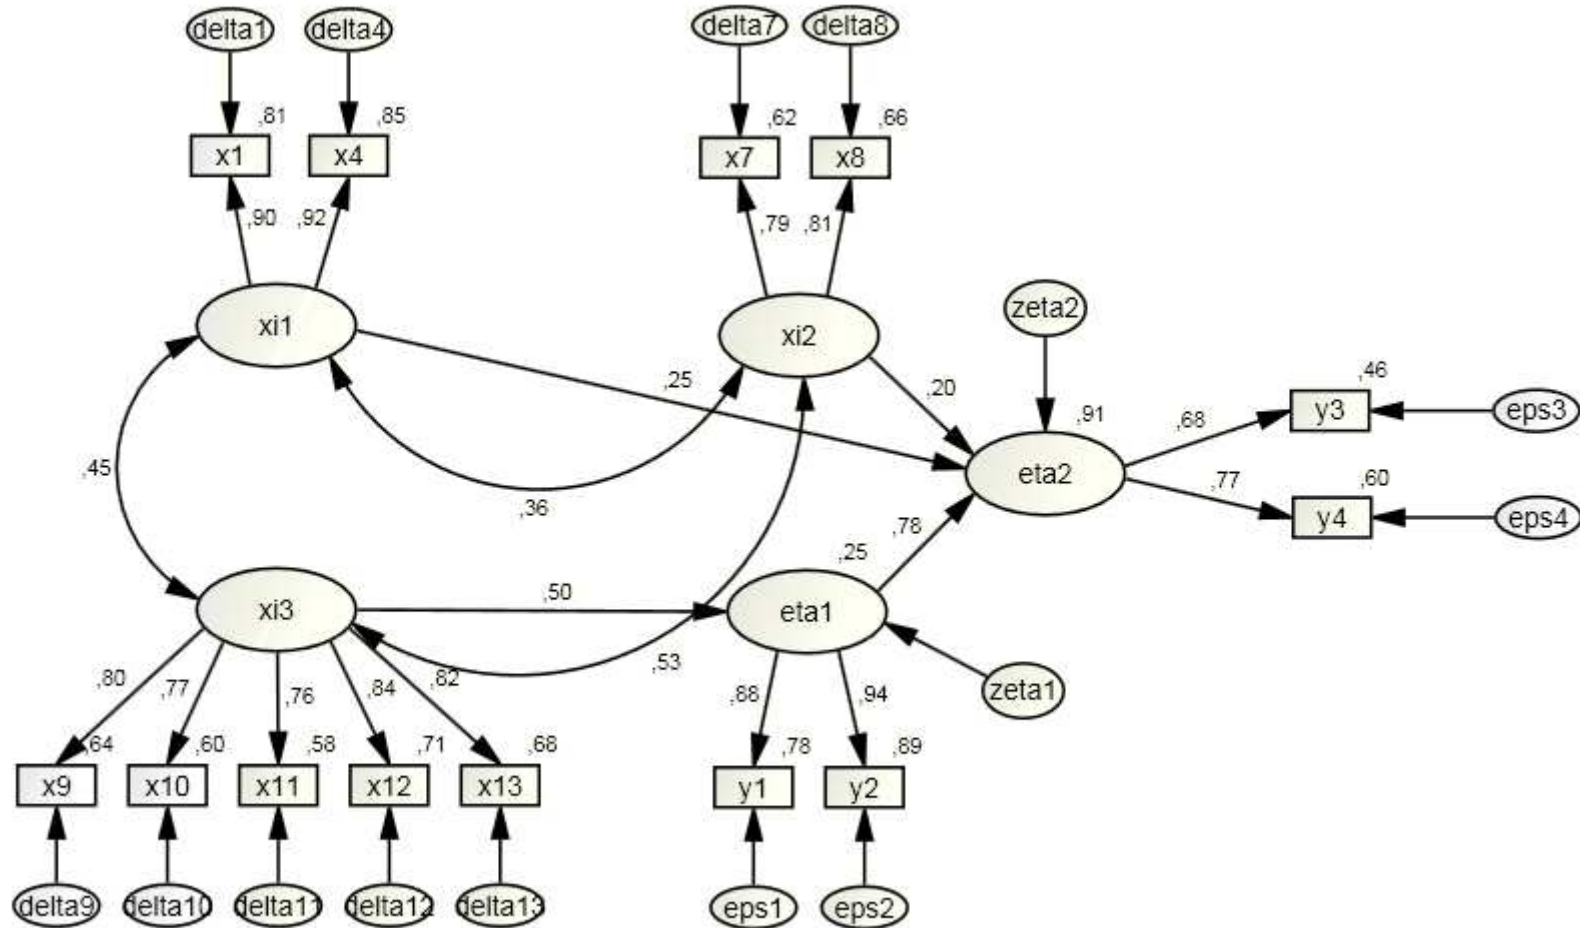
- a) Su escaso poder de explicación en varianza de los constructos (o variables latentes) a los que estaban asociados.
- b) Se considera que mantenerlos en el análisis puede distorsionar los resultados.

Junto a estas dos razones, hay que señalar que además, con la eliminación de estas variables indicadoras se consigue que el nivel de explicación del constructo  $\eta_2$ , que representa la satisfacción global de los ciudadanos con los servicios en el municipio no disminuya, ya que con este nuevo modelo más simplificado o "corregido" se explica el 91% de su varianza; exactamente igual al nivel de explicación con la estimación del modelo con todas las variables indicadoras.

## 6. Corrección y mejora del modelo

Normalmente, se rechazan los modelos, dada su excesiva complejidad y las numerosas restricciones a las que están sujetos. Ante este escenario, los modelos han de ser modificados para mejorar tanto en su ajuste como en complejidad.

Gráfico 9. Modelo 2 "corregido". Estimación por Máxima Verosimilitud (estimaciones estandarizadas).





El análisis de la consistencia interna reveló valores alfa de Cronbach para el factor  $\xi_1$  ("Limpieza y recogida de residuos") ligeramente superiores a .90. Hay que recordar que en este modelo (Modelo 2 "corregido"), en la construcción de dicho factor, únicamente intervienen 2 ítems ( $x_1$ : valoración, en una escala de 0 a 10, de la frecuencia en la recogida de residuos y  $x_4$ : valoración, en una escala de 0 a 10, del funcionamiento del servicio de recogida de residuos). A pesar de la reducción del número de ítems para este factor, la consistencia interna más favorable, pues el valor del alfa de Cronbach pasa de .868 a .905.

Igualmente, otra de las subescalas, más concretamente la que se refiere al factor  $\xi_2$  ("Servicios Sanitarios"), reflejó un nivel de consistencia interna superior a la obtenida con el Modelo 1, pasando de un alfa de Cronbach de .735 a .784.

Sin embargo, en el caso del factor  $\eta_2$  ("Satisfacción ciudadana"), la consistencia interna se ve sensiblemente reducida al extraer del análisis el ítem que expresa la valoración que los ciudadanos hacen de la calidad de vida en el municipio, pasando de .741 a .712 en su valor alfa de Cronbach.

Tabla 19. Fiabilidad de escala y consistencia interna. Alpha de Cronbach del Modelo 2 "corregido".

	Nº de Ítems	Alpha de Cronbach
Xi1	2	0,905
Xi2	2	0,784
Xi3	5	0,908
Eta1	2	0,921
Eta2	2	0,712
Total	13	0,902

En definitiva, a la luz de los datos contenidos en la Tabla 19, se pudo comprobar que esta versión “corregida” del modelo inicialmente propuesto reunía las condiciones de consistencia interna teóricamente exigibles, o lo que es lo mismo, se constató que la estructura factorial del mismo estaba justificada.

Para constatar la fiabilidad de medida se presentan en la Tabla 20 los valores de varianza explicada en la variable por el constructo correspondiente; destacando sobre todas las demás, la varianza explicada en  $\eta_2$ , o lo que es lo mismo, en la satisfacción ciudadana global.

Tabla 20.  $R^2$

Estimate		Estimate	
eta1	0,249	x9	0,638
eta2	0,909	x10	0,595
x8	0,661	x11	0,581
x7	0,623	x12	0,713
y4	0,599	x13	0,680
y3	0,463	x4	0,853
y1	0,782	x1	0,809
y2	0,886		

Las cargas factoriales de este modelo “corregido” representado en el Gráfico 7 oscilan entre .68 y .94 con unos índices de fiabilidad aceptables en prácticamente todos los casos y en donde todos los constructos han quedado bien definidos, especialmente  $\xi_1$  y  $\eta_1$ .

En el caso de las correlaciones entre los constructos, hay que decir que al alterar los ítems que saturan en tres de los cinco factores del modelo ( $\xi_1$ ,  $\xi_2$  y  $\eta_2$ ) provoca que éstas también varíen sensiblemente.

De este modo, se completó la aproximación en dos pasos, tal y como recomiendan Anderson y Gerbing (1988), al realizarse en primer lugar un modelo de medida que permitió dar validez de constructo a los instrumentos, lo cual se corresponde con un análisis factorial confirmatorio y, en segundo lugar, un modelo estructural, que sirvió para analizar las relaciones entre las percepciones de satisfacción con determinados servicios públicos (limpieza y recogida de residuos, los servicios sanitarios, las infraestructuras viarias) y la valoración de la gestión realizada en el municipio, y la satisfacción ciudadana en un sentido más amplio y global.

En los anexos del trabajo se adjuntan también los gráficos correspondientes a la estimación del Modelo 2 “corregido” por Mínimos Cuadrados Generalizados y Distribución Libre Asintótica, así como las tablas comparativas entre los tres métodos de estimación empleados con el resumen de las medidas de ajuste global.

Hablando ahora de la bondad de ajuste del Modelo 2 “corregido”, es importante recordar que, como ya se ha apuntado con anterioridad, el estadístico chi-cuadrado es muy sensible al tamaño muestral y con muestras amplias el test tiende a ser estadísticamente significativo (Jöreskog y Sörbom, 1989), resulta conveniente tener en cuenta la ratio  $\chi^2/df$  que, para autores como Bentler (1989) se considera aceptable cuando toma un valor inferior a 5, mientras que en investigaciones más restrictivas se establece que para un buen ajuste, a esta ratio ha de corresponderle un valor menor que 2 (Ullman, 2001).

Así, a la luz de los resultados contenidos en la Tabla 21 que contiene el número de parámetros estimados por el método de máxima verosimilitud, el valor del estadístico chi-cuadrado del modelo, sus correspondientes grados de libertad y la ratio  $\chi^2/df$ , podemos comprobar que, en efecto, el valor de este indicador resulta más favorable si lo comparamos con el que se obtuvo para el modelo inicial (Modelo 1). Más concretamente, se pasa del 2,91 del Modelo 1 a 2,19 del Modelo “corregido”.

Tabla 21. Resumen del Modelo 2 “corregido”. Estimación por Máxima Verosimilitud.

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	46	127,543	58	0,000	2,199
Saturated model	104	0,000	0	-	-
Independence model	26	2029,176	78	0,000	26,015

Al igual que para la estimación de los parámetros del Modelo 1, se presentan en la Tabla 20, las estimaciones de los parámetros del Modelo “corregido” por máxima verosimilitud, comprobándose que todos los valores de proporción crítica (C.R.) son mayores a 2, lo que significa que todos los parámetros resultaron estadísticamente significativos.

Tabla 22. Estimaciones de Máxima Verosimilitud del Modelo 2 “corregido”.

		Estimate	S.E.	C.R.	S. Estimate	Sig.
eta1	<--- xi3	0,515	0,068	7,519	0,499	0,000
eta2	<--- eta1	0,450	0,044	10,321	0,776	0,000
eta2	<--- xi1	0,141	0,035	3,995	0,25	0,000
eta2	<--- xi2	0,147	0,050	2,957	0,199	0,003
x1	<--- xi1	1,000			0,9	
x4	<--- xi1	0,916	0,070	13,085	0,923	0,000
x13	<--- xi3	1,000			0,824	
x12	<--- xi3	1,098	0,071	15,535	0,845	0,000
x11	<--- xi3	0,966	0,073	13,218	0,762	0,000
x10	<--- xi3	0,851	0,063	13,527	0,772	0,000
x9	<--- xi3	1,044	0,073	14,389	0,799	0,000
y2	<--- eta1	1,000			0,941	
y1	<--- eta1	0,917	0,048	19,247	0,884	0,000
y3	<--- eta2	1,000			0,681	
y4	<--- eta2	1,167	0,104	11,184	0,774	0,000
x7	<--- xi2	1,000			0,789	
x8	<--- xi2	1,086	0,129	8,438	0,813	0,000

Por su parte, los modelos de medida y estructural de este Modelo 2 "corregido" quedan se representan a través de las siguientes ecuaciones:

$$\begin{array}{ll}
 \text{eta1} = 0,515 * \text{xi3} & \text{x10} = 0,851 * \text{xi3} \\
 \text{eta2} = 0,450 * \text{eta1} & \text{x9} = 1,044 * \text{xi3} \\
 \text{eta2} = 0,141 * \text{xi1} & \text{y2} = 1,000 * \text{eta1} \\
 \text{eta2} = 0,147 * \text{xi2} & \text{y1} = 0,917 * \text{eta1} \\
 \text{x1} = 1,000 * \text{xi1} & \text{y3} = 1,000 * \text{eta2} \\
 \text{x4} = 0,916 * \text{xi1} & \text{y4} = 1,167 * \text{eta2} \\
 \text{x13} = 1,000 * \text{xi3} & \text{x7} = 1,000 * \text{xi2} \\
 \text{x12} = 1,098 * \text{xi3} & \text{x8} = 1,086 * \text{xi2} \\
 \text{x11} = 0,966 * \text{xi3} &
 \end{array}$$

Asimismo, se adjuntan en las Tablas 23 a 26 los resultados de todos los índices de ajuste global (resultados de las medidas absolutas de ajuste, medidas incrementales de ajuste y medidas de ajuste de parsimonia).

Tabla 23. Función de discrepancia. Resumen de los modelos. Modelo 2 "corregido".

Model	FMIN	LO go	HI go
Default model	0,518	0,165	0,431
Saturated model	0,000	0,000	0,000
Independence model	8,249	7,350	8,543

Tabla 24. Medidas de ajuste global del Modelo 2 "corregido". Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
GFI	0,937	1,000	-
NCP	69,543	0,000	1951,176
LO 90	40,687	0,000	1808,052
HI 90	106,138	0,000	2101,665
RMSEA	0,07	-	0,319
LO 90	0,053	-	0,307
HI 90	0,086	-	0,331
SRMR	0,069	-	-
PCLOSE	0,025	-	0,000

Tabla 25. Medidas incrementales de ajuste del Modelo 2 "corregido". Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
NFI	0,937	1,000	0,000
RFI	0,915	-	0,000
IFI	0,965	1,000	0,000
TLI	0,952	-	0,000
CFI	0,964	1,000	0,000
AGFI	0,953	-	-

Tabla 26. Medidas de ajuste de parsimonia del Modelo 2 "corregido".  
Estimación por Máxima Verosimilitud.

Medida de Ajuste	Default model	Saturated model	Independence model
PNFI	0,697	0,000	0,000
PGFI	0,697	-	-
AIC	219,543	208,000	2081,176
BCC	225,095	220,552	2084,314
HOELTER 0.5 index	149	-	13
HOELTER 0.1 index	166	-	14

En definitiva, los resultados mostraron unos índices de ajuste aceptables:  $\chi^2(58, N=247)=127.543$ ,  $p=.000$ ;  $\chi^2/df=2.19$ ;  $GFI=0.937$ ;  $CFI=.964$ ;  $IFI=.965$ ;  $TLI=.952$ ;  $RMSEA=.07$ ;  $SRMR=.069$ ;  $AIC=219.543$ . Los pesos (coeficientes) de regresión estandarizados de los ítems oscilaron entre .20 y .94, que fueron, todos ellos, estadísticamente significativos. Asimismo, las correlaciones entre los factores también lo fueron ( $p<.001$ ), cuyos coeficientes oscilaron entre .36 (entre  $\xi_1$ , factor del servicio de limpieza y recogida de residuos, y  $\xi_2$ , factor de los servicios sanitarios), .45 (entre  $\xi_1$  y  $\xi_3$ , que representa las infraestructuras viarias) y .53 (entre  $\xi_2$  y  $\xi_3$ ).

Partiendo del objetivo o con el que nació este proyecto (estudiar la satisfacción ciudadana con los servicios municipales mediante análisis causal con ecuaciones estructurales), y llegados a este punto, ha quedado demostrado que la importancia de todos los elementos de un mismo servicio (ítems del cuestionario de la encuesta de satisfacción) no es la misma y, en consecuencia, la influencia que ejercen sobre el grado de satisfacción de los ciudadanos y sus percepciones a cerca de los servicios municipales, tampoco lo es.

Así, tal y como se puede apreciar a la vista del Gráfico 9, se ha visto que en el caso particular de la Limpieza y Recogida de Residuos, los elementos que ejercen una mayor influencia en la valoración de este servicio son: la frecuencia en la recogida de residuos y el funcionamiento de la recogida. Cuestiones como la recogida selectiva de residuos o el número de contenedores para la recogida selectiva juegan un papel secundario en la valoración global del servicio de limpieza.

La misma situación se repite en el caso de la sanidad y los servicios sanitarios en el municipio, donde los elementos realmente determinantes en la valoración que los ciudadanos emiten de esta área son los centros de salud y los médicos de atención primaria.

Siguiendo con la idea de depurar al máximo el modelo, en la configuración de la satisfacción global de los ciudadanos ( $\eta_2$ ) se eliminó la variable  $y_5$ ; variable observada que representa la valoración que los ciudadanos hace de la calidad de vida en el municipio. El hecho de eliminar esta variable del estudio de la satisfacción tiene su explicación en la teoría de la desconfirmación, que entiende que conceptos como satisfacción y calidad son dos caras de la misma moneda. En otras palabras, aquel ciudadano que esté satisfecho con los servicios municipales, valorará positivamente la calidad de vida en su municipio de residencia. Esta es la razón fundamental por la cual se ha eliminado esta última variable del modelo, pues entendemos que la presencia de la variable  $y_4$  (satisfacción con los servicios prestados en el municipio) minimiza su contribución.

Una vez que el sub-modelo de medida era el adecuado, el último paso consistía en determinar la influencia que las áreas y servicios introducidos ejercían sobre la satisfacción global de los ciudadanos; esto es, estimar el sub-modelo estructural.



El modelo de regresión para la satisfacción global de los ciudadanos presenta un nivel de explicación muy elevado, ya que  $R^2=0.909$  y en el que todas las variables independientes resultan estadísticamente significativas ( $p<.01$ ). De menor a mayor orden de influencia: ( $\xi_2$ ) valoración de la Sanidad y los Servicios Sanitarios ( $\beta=0.20$ ), ( $\xi_1$ ) la valoración del servicio de Limpieza y Recogida de Residuos ( $\beta=0.25$ ) y, por último, ( $\eta_1$ ) la valoración de la Gestión Municipal ( $\beta=0.78$ ). Es decir, los coeficientes de regresión revelan que es esta última variable,  $\eta_1$ , la que tiene mayor poder de predicción del grado de satisfacción global de los ciudadanos.

Y esto es así porque en ellos (los gestores y responsables municipales) recae la obligación de facilitar la prestación de los servicios básicos y cuyas decisiones condicionan la creación y mantenimiento de las infraestructuras viarias e influyen en la prestación de los servicios de limpieza y recogida de residuos.

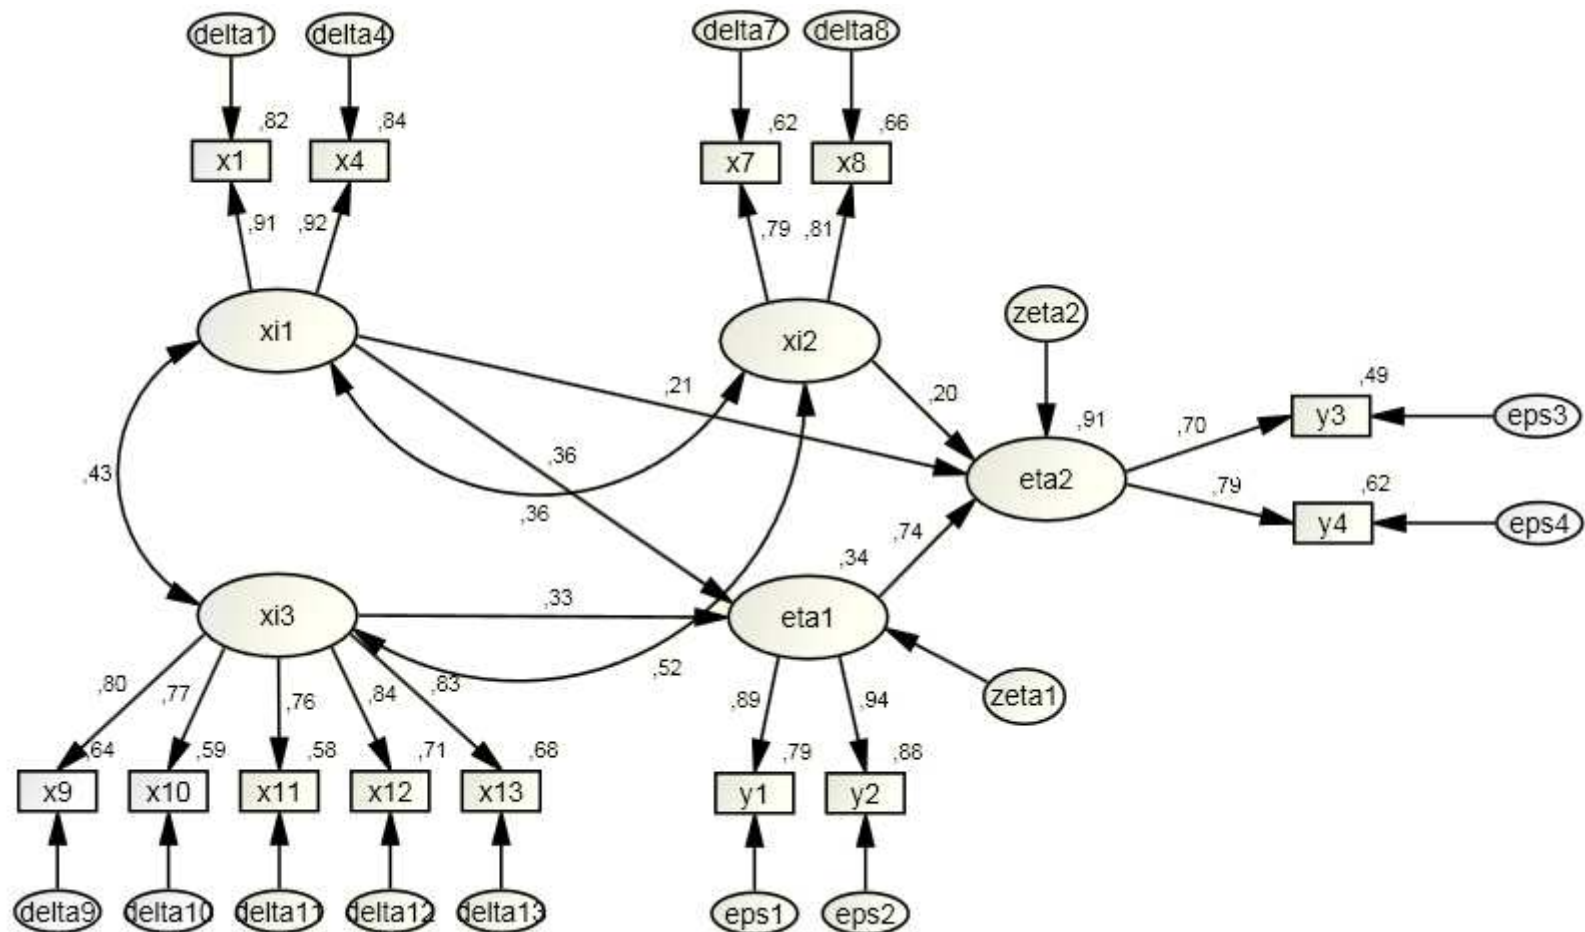
## 7. "Modification index" (MI) con AMOS

AMOS ofrece la opción "Modification Indices" en el proceso de estimación de los SEM como mecanismo con el fin de mejorar la bondad de ajuste. Para la modificación de los índices es necesario modificar el modelo incorporando "paths", que pueden ser tanto líneas de regresión como correlaciones; esto es, incluir nuevas relaciones que no habían sido contempladas con anterioridad. Esta opción es una herramienta útil que indica una posible reducción en el valor del estadístico  $\chi^2$  y en todas las medidas de bondad de ajuste. Sin embargo, la decisión de introducir estas modificaciones en el modelo depende, principalmente, de las implicaciones teóricas que trae consigo cada modificación.

Así pues, como paso último de la modelización de la satisfacción con ecuaciones estructurales se empleó dicha opción. Como resultado se observó que el modelo mejoraba sustancialmente si se introducía un coeficiente de regresión entre dos de los factores del modelo.

La modificación suponía incluir una regresión utilizando  $\xi_1$  (variable latente exógena que representa la valoración del servicio de Limpieza y Recogida de Residuos) para predecir  $\eta_1$  (variable latente endógena que representa la valoración de la gestión municipal), lo cual condujo a que tanto el modelo de medida como el estructural resultasen más favorables. De hecho se produjo una reducción importante del valor del estadístico  $\chi^2$ , pasando de  $\chi^2(58, N=247)=127.543$  a  $\chi^2(57, N=247)=99.602$ . A continuación se representa este último modelo (Modelo 3) en el Gráfico 10, para cuya estimación se ha utilizado máxima verosimilitud. Al igual que en los gráficos de los modelos anteriores, las estimaciones de los parámetros están estandarizadas.

Gráfico 10. Modelo 3. Estimación por Máxima Verosimilitud (estimaciones estandarizadas).



La introducción del efecto directo de la valoración del Servicio de Limpieza y Recogida de Residuos sobre la valoración de la Gestión Municipal es más que justificada, pues de todos los servicios que se introducen en el modelo, es el único de competencia exclusivamente municipal, por lo que los ciudadanos identifican a la administración local (y con ello, nos referimos tanto al gobierno municipal en general, como al alcalde en particular) como responsable de su funcionamiento; y por tanto, la valoración que emiten sobre la frecuencia en la recogida de residuos y del funcionamiento del servicio de recogida es consecuencia de la gestión realizada.

A cerca de la bondad de ajuste, los resultados reflejaron los siguientes índices:  $\chi^2(57, N=247)=99.602$ ,  $p=.000$ ;  $\chi^2/df=1.747$ ; GFI=.950; CFI=.978; IFI=.978; TLI=.970; RMSEA=.055; SRMR=.041; AIC=193.602. Los pesos (coeficientes) de regresión estandarizados de los ítems oscilaron entre .21 y .92, que resultaron, todos ellos, estadísticamente significativos. Las correlaciones entre los factores, todas ellas estadísticamente significativas ( $p<.001$ ), oscilaron entre .36 (entre  $\xi_1$ , factor del servicio de limpieza y recogida de residuos, y  $\xi_2$ , factor de los servicios sanitarios), .43 (entre  $\xi_1$  y  $\xi_3$ , que representa las infraestructuras viarias) y .52 (entre  $\xi_2$  y  $\xi_3$ ).

Al igual que para los Modelos 1 y 2 se presenta tanto la tabla resumen del modelo como las tablas con las medidas de bondad de ajuste global (Tablas 27 a 32).

Tabla 27. Resumen del Modelo 3. Estimación por Máxima Verosimilitud

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	47	99,602	57	0,000	1,747
Saturated model	104,000	0	0		
Independence model	26	2029,176	78	0,000	26,015

Tabla 28. Función de discrepancia. Resumen de los modelos

Model	FMIN	Fo	LO 90	HI 90
Default model	0,405	0,173	0,076	0,302
Saturated model	0,000	0,000	0,000	0,000
Independence model	8,249	7,932	7,350	8,543

Tabla 29. Medidas de ajuste global del Modelo 3

Medida de Ajuste	Default model	Saturated model	Independence model
GFI	0,951	1,000	-
NCP	42,602	0,000	1951,176
LO 90	18,716	0,000	1808,052
HI 90	74,346	0,000	2101,665
RMSEA	0,055	-	0,319
LO 90	0,037	-	0,307
HI 90	0,073	-	0,331
SRMR	0,041	-	-
PCLOSE	0,002	-	0,000

Tabla 30. Medidas incrementales de ajuste del Modelo 3

Medida de Ajuste	Default model	Saturated model	Independence model
NFI	0,951	1,000	0,000
RFI	0,933	-	0,000
IFI	0,978	1,000	0,000
TLI	0,970	-	0,000
CFI	0,978	1,000	0,000
AGFI	0,964	-	0,000

Tabla 32. Medidas de ajuste de parsimonia del Modelo 3

Medida de Ajuste	Default model	Saturated model	Independence model
PNFI	0,695	0,000	0,000
PGFI	0,695	-	-
AIC	193,602	208	2081,176
BCC	199,275	220,552	2084,314
HOELTER 0.5 index	187	-	13
HOELTER 0.1 index	210	-	14

Finalizando con la presentación de los resultados, se adjuntan las Tablas 33 y 34, con las estimaciones de los parámetros por máxima verosimilitud y los coeficientes de determinación correspondientes.

Tabla 23. Estimaciones de Máxima Verosimilitud Modelo 3

			Estimate	S.E.	C.R.	S. Estimate	Sig.
eta1	<---	xi3	0,339	0,070	4,842	0,331	0,000
eta1	<---	xi1	0,349	0,065	5,358	0,363	0,000
eta2	<---	eta1	0,453	0,045	10,028	0,745	0,000
eta2	<---	xi1	0,123	0,037	3,362	0,211	0,000
eta2	<---	xi2	0,152	0,050	3,043	0,196	0,002
x1	<---	xi1	1,000			0,907	
x4	<---	xi1	0,902	0,061	14,750	0,916	0,000
x13	<---	xi3	1,000			0,826	
x12	<---	xi3	1,097	0,071	15,555	0,845	0,000
x11	<---	xi3	0,965	0,073	13,230	0,763	0,000
x10	<---	xi3	0,848	0,063	13,513	0,77	0,000
x9	<---	xi3	1,048	0,072	14,488	0,803	0,000
y2	<---	eta1	1,000			0,938	
y1	<---	eta1	0,924	0,047	19,635	0,888	0,000
y3	<---	eta2	1,000			0,696	
y4	<---	eta2	1,170	0,105	11,162	0,789	0,000
x7	<---	xi2	1,000			0,789	
x8	<---	xi2	1,085	0,127	8,513	0,813	0

Tabla 34.  $R^2$

Estimate		Estimate	
eta1	0,344	y2	0,879
eta2	0,915	x9	0,644
x8	0,66	x10	0,594
x7	0,623	x11	0,582
y4	0,623	x12	0,714
y3	0,485	x13	0,682
y1	0,788	x4	0,84
x1	0,822		

Finalmente, se ha llegado a un modelo de ecuaciones estructurales óptimo, con el que no sólo las medidas de bondad de ajuste son más favorables (en comparación con las correspondientes al Modelo 1 y 2), sino que también lo son los coeficientes de determinación de muchas de variables observadas y, fundamentalmente, de la variable latente que representa la valoración de la gestión municipal; variable que, tal y como ya se ha explicado en el punto anterior, supone la mayor influencia en la predicción de la satisfacción global de los ciudadanos. En resumen, el Modelo 3 consigue mejorar tanto el sub-modelo de medida como el sub-modelo estructural.





## Conclusiones y futuras líneas de investigación

Este Proyecto de Investigación tenía un doble objetivo. En primer lugar presentar de una forma clara y sencilla los principios básicos y conceptos más relevantes en los modelos de ecuaciones estructurales (*structural equation modelling-SEM*), y en segundo lugar, presentar un ejemplo empírico de este tipo de análisis empleando para ello los datos reales de una encuesta de satisfacción ciudadana con los servicios públicos en el municipio.

En concreto, el aporte más destacado del modelo al que finalmente se ha llegado consiste en la distinción entre los efectos de los distintos servicios sobre la satisfacción global de los ciudadanos. Si bien, todas y cada uno de los servicios públicos incluidos en el análisis ejercen un efecto significativo y positivo sobre el grado de satisfacción, el modo en que lo ejercen no es el igual; así como tampoco es igual la importancia que tienen diferentes cuestiones dentro de un mismo servicio en la valoración global del mismo.

Desde esta perspectiva se ha construido un estudio de la satisfacción ciudadana desde dos planos diferentes: un plano global y más general en el que se estudian qué servicios incurren en el aumento de la satisfacción y, un plano más particular en el que dentro de cada servicio se analiza cuáles de sus elementos internos son los responsables de la valoración que los ciudadanos hacen de dicho servicio. La aplicación empírica de los 3 modelos de ecuaciones estructurales presentados en este proyecto así lo demuestra.

En definitiva, el modelo final (Modelo 3) podrá ser utilizado como mecanismo a través del cual mejorar la eficiencia de la propia administración local, en el sentido que permite señalar tanto los servicios como los elementos internos de cada uno de ellos que tienen mayor incidencia en la satisfacción e insatisfacción ciudadana. Este mayor conocimiento sobre el efecto de los servicios y de sus elementos impulsores clave en las percepciones de los ciudadanos, ayudará a rediseñar la distribución de los recursos de los que dispone la administración local, reequilibrando la balanza de su gestión.

En resumen, los hallazgos a los que se han llegado en este trabajo pueden resumirse en:

- La importancia preponderante de la valoración de la gestión municipal de los responsables políticos en el grado de satisfacción.
- La influencia de la valoración de servicios públicos de titularidad municipal o que los ciudadanos identifican como responsabilidad de la administración local. Hablamos, especialmente, del funcionamiento del servicio de limpieza y recogida de residuos y su frecuencia; así como servicios y prestaciones que garanticen la salud de los ciudadanos.
- La influencia indirecta del mantenimiento de las infraestructuras viarias en el grado de satisfacción global.

En consecuencia, este Proyecto Fin de Máster es una buena prueba de que la aplicación de modelos de ecuaciones estructurales para el estudio de la satisfacción ciudadana no sólo es oportuna, sino que además supone una herramienta de gran utilidad; un grado de conveniencia que autores como Zanella ya habían señalado con anterioridad, destacando que los modelos SEM representan una de las herramientas estadísticas más refinadas a nuestra disposición para el estudio de los constructos conceptuales. Siguiendo palabras de Zanella, estos modelos "...permiten un estudio completo del constructo conceptual de la satisfacción del consumidor" (Zanella, 2001).

---

Por su parte, el aprendizaje de la metodología de los modelos de ecuaciones estructurales que desarrolla este Proyecto Fin de Máster es un importante punto de partida para la realización de una futura tesis doctoral. Ha servido, además, para identificar las limitaciones propias del cuestionario de la encuesta de satisfacción cuyos resultados han sido analizados.

El objetivo que inspira esta futura investigación consiste en construir índices de satisfacción tanto para cada uno de los servicios públicos indicados como un índice de satisfacción global; todos ellos calculados para cada uno de los ayuntamientos de la provincia de A Coruña.

La clasificación de los municipios en función de criterios poblacionales, permitirá introducir mecanismos de comparación entre las puntuaciones obtenidas por los ayuntamientos (con similares cargas poblacionales y características internas) para cada uno de los índices construidos, perfilándose de este modo y a través criterios de benchmarking, un mapa de satisfacción de la provincia.

Nuevamente es hará uso de encuestas de satisfacción para conocer la opinión de los ciudadanos a cerca de la valoración de los servicios, lo que cual implicará realizar el estudio demoscópico a una muestra de ayuntamientos pertenecientes a cada rango poblacional. Junto a ello, será obligado realizar una búsqueda y generación de nuevos ítems con el fin obtener una muestra amplia de cuestiones que capturen todos los aspectos o dimensiones de los constructos que se determinen objeto de análisis.



## Bibliografía

- Anderson, J. C., & Gerbing, D. W. (1988). Structural equation modeling in practice: A review and recommended two-step approach. *Psychological Bulletin*, 103, 411-423.
- Andreassen, T.W. (1995). (Dis)satisfaction with public services: the case of public transportation. *Journal of services marketing*, Vol. 9, N° 5, pp. 30-41.
- Arias, B. (2008). Desarrollo de un ejemplo de análisis factorial confirmatorio con LISREL, AMOS y SAS. Seminario de actualización en Investigación sobre Discapacidad SAID. Universidad de Valladolid
- Asociación Española de Contabilidad y Administración de Empresas (AECA, 1997). Indicadores de Gestión para la Entidades Públicas. N°. 16.
- Arbuckle, J. L. & Wothke, W. (1999). *Amos 4.0 user's guide*. Chicago: SPSS/SmallWaters.
- Barret, P. (2006). Structural equation modeling: Adjudging model fit. *Science Direct. Personality and Individual Differences*, Vol 42, pp 815-824.
- Bollen, K.A. (1989). *Structural equations with latent variables*. New York: J. Wiley & Sons.
- Bollen, K.A. y Long, J.S. (1993). *Testins structural equation models*. Newbury Park, CA: Sage.
- Bollen, K.A. (2001). Two-Stage Least Squares and Latent Variable Models: Simultaneous Estimation and Robustness to Misspecifications. Ch 7, pp 199-138 in R.
- Brown, T. A. (2006). *Confirmatory Factor Analysis for Applied Research*. New York: The Guilford Press.
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. In Bollen, K. A., & Long, J. S. (Eds.), *Testing structural equation models*, pp 136-162. Newbury Park, CA: Sage.

- Cudeck, S. du Toit and D. Sorbom (eds) *Structural Equation Modeling: Present and Future: A Festschrift in honor of Karl Joreskog*, Scientific Software International: Lincolnwood.
- González-Cutre Coll, D., Sicilia Camacho, A. y Moreno Murcuja, J.A. (2008). Modelo cognitivo-social de la motivación de logro en educación física. *Psicothema*, Vol. 20, nº4, pp 642-651.
- Hoyle, R. H. (Ed.) (1995). *Structural equation modeling: Concepts, issues, and applications*. Thousand Oaks: Sage.
- Hoyle, R. H., & Panter, A. T. (1995). Writing about structural equation models. In R. H. Hoyle (Ed.), *Structural equation modeling* (pp. 158-176). Thousand Oaks, CA: Sage.
- Hu, L.-T., & Bentler, P. M. (1995). Evaluating model fit. In R. H. Hoyle (Ed.), *Structural equation modeling* (pp. 76-99). Thousand Oaks, CA: Sage.
- Hu, L, -T., & Bentler, P.M. (1999). Cut-off criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6, 1-55.
- Jöreskog, K.G.(1974). Analyzing psychological data by structural analysis of covariance matrices. In R.C. Atkinson, D.H. Krantz, R.D. Luce, & P. Suppes (eds.). *Contemporary developments in mathematical psychology*. S. Francisco (CA): Freeman.
- Jöreskog, K.G.(1979a). Statistical estimation of structural models in longitudinal-developmental investigations. In J.R. Nesselroade & P.B. Baltes. *Longitudinal research in the study of the behavior and development*. New York: Academic Press.
- Jöreskog, K.G.(1979b). A general approach to confirmatory maximum likelihood factor analysis with addendum. In K.G. Jöreskog & D. Sörbom. *Advances in factor analysis and structural equation models*. Cambridge (MA): Abt Books.
- Jöreskog, K.G., Sörbom, D., 1982. Recent developments in structural equation modeling. *Journal of Marketing Research* 19, 404-416.
-

- Klein, R. B. (1998). *Principles and practice of structural equation modeling*. New York: Guilford.
- Lozano, S. (2006). Validación de un modelo de medida de la auto-eficacia en la toma de decisión de la carrera. *Revista de Investigación Educativa*. Vol.24, 423-442.
- McDonald, R. P., & Ho, M.-H. R. (2002). Principles and practice in reporting structural equation analyses. *Psychological Methods*, 7, 64-82.
- Miller, T. I., Kobayashi, M. Miller. (2000c). *Citizen surveys: How to do them, how to use them, what they mean*. Washington, D.C.: International City/County Management Association.
- Muthén, L. K., & Muthén, B. O. (1998-2001). *Mplus user's guide* (2nd ed.). Los Angeles, CA: Muthén & Muthén.
- Olsson, U.H., Foss, T., Troye, S. V., & Roy D. Howell (2000). The Performance of ML, GLS and WLS Estimation in Structural Equation Modeling Under Conditions of Misspecification and Nonnormality. *Structural Equation Modeling*, 7 (4), 557-595.
- Osborne, D. E. y Gaebler, T. (1992). *Reinventing Government: How the entrepreneurial spirit is transforming the public sector*. Addison-Wesley Pub. Co.
- Parasuraman, A.; Zeithaml, V. A. y Berry, L.L. (1994a). "Reassessment of expectations as a comparison standard in measuring service quality: implications for further research". *Journal of Marketing*. Vol. 58 (Enero): 11-124.
- Peña, D. Romo, J. (1997). *Introducción a la Estadística para las Ciencias Sociales*. McGraw Hill.
- Rodríguez Vargas, J. Carlos (2006). Validación del modelo psicoeconómico del consumidor: análisis con ecuaciones estructurales. *Pensamiento y Gestión*, nº20, pp 1-54.
- Russell, D. W., Kahn, J. H., Spoth, R., & Altmaier, E. M. (1998). Analyzing data from experimental studies: A latent variable structural equation modeling approach. *Journal of Counseling Psychology*, 45, 18-29.
-

- Ullman, J. B. (2001). Structural equation modeling. En Tabachnick, B.G., & Fidell, L. S. (2001). *Using Multivariate statistics* (4ª ed.): 653-771. Needham Heights, MA: Allyn & Bacon.
- Wright, S., 1921. Correlation and causation. *Journal of Agricultural Research* 20, 557–585.
- Wright, S., 1934. The method of path coefficients. *Annals of Mathematical Statistics* 5, 161–215.
- Zanella, A. (2001). Measures and models of customer satisfaction: the underlying conceptual construct and comparison of different approaches. The 6th TQM World Congress, Saint Petersburg.
- Zeithaml, V.A. y Bitner, M.J. (2002). *Marketing de servicios. Un enfoque de integración del cliente a la empresa*. Mc Graw Hill. 2ª edición. México.



## Resumen del Modelo 2 "corregido". Comparativa con tres métodos de estimación.

Modelo 1	ML					GLS					ADF				
	NPAR	Chi-square	DF	P	Chi-square/DF	NPAR	Chi-square	DF	P	Chi-square/DF	NPAR	Chi-square	DF	P	Chi-square/DF
Default model	46	127,543	58	0,000	2,199	33	111,144	58	0,000	1,916	33	104,385	58	0,000	1,800
Saturated model	104	0,000	0	-	-	91	0,000	0	-	-	91	0,000	0	-	-
Independence model	26	2029,176	78	0,000	26,015	13	412,31	78	0,000	5,286	13	507,724	78	0,000	6,509

## Función de discrepancia del Modelo 2 "corregido". Comparativa con tres métodos de estimación.

Modelo 1	ML			GLS			ADF		
	FMIN	LO 90	HI 90	FMIN	LO 90	HI 90	FMIN	LO 90	HI 90
Default model	0,518	0,165	0,431	0,452	0,110	0,353	0,424	0,088	0,321
Saturated model	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
Independence model	8,249	7,350	8,543	1,676	1,116	1,633	2,064	1,472	2,052

Medidas de ajuste global del Modelo 2 "corregido". Comparativa con tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
GFI	0,967	1,000	-	0,93	1,000	0,742	0,907	1,000	0,549
NCP	69,543	0,000	1951,176	53,144	0,000	334,310	46,385	0,000	429,724
LO go	40,687	0,000	1808,052	27,158	0,000	274,464	21,667	0,000	362,207
HI go	106,138	0,000	2101,665	86,935	0,000	401,674	78,941	0,000	504,734
RMSEA	0,07	-	0,319	0,061	-	0,132	0,057	-	0,150
LO go	0,053	-	0,307	0,044	-	0,120	0,039	-	0,137
HI go	0,086	-	0,331	0,078	-	0,145	0,74	-	0,162
SRMR	0,069	-	-	0,069	-	-	0,0771	-	-
PCLOSE	0,025	-	0,000	0,140	-	0,000	0,243	-	0,000

Medidas incrementales de ajuste del Modelo 2 "corregido". Comparativa con tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
NFI	0,937	1,000	0,000	0,730	1,000	0,000	0,794	1,000	0,000
RFI	0,915	-	0,000	0,637	-	0,000	0,724	-	0,000
IFI	0,965	1,000	0,000	0,850	1,000	0,000	0,897	1,000	0,000
TLI	0,952	-	0,000	0,786	-	0,000	0,855	-	0,000
CFI	0,964	1,000	0,000	0,841	1,000	0,000	0,892	1,000	0,000
AGFI	0,953	-	-	0,891	-	0,699	0,855	-	0,474

Medidas de ajuste de parsimonia del Modelo 2 "corregido". Comparativa con tres métodos de estimación.

Medida de Ajuste	ML			GLS			ADF		
	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model	Default model	Saturated model	Independence model
PNFI	0,697	0,000	0,000	0,543	0,000	0,000	0,591	0,000	0,000
PGFI	0,697	-	-	0,593	-	0,636	0,578	-	0,471
AIC	219,543	208,000	2081,176	177,144	182,000	438,310	170,385	182,000	533,724
CAIC	-	-	-	325,954	592,354	496,932	319,194	592,354	592,346
HOELTER 0.5 index	149	-	13	170	-	60	181	-	49
HOELTER 0.1 index	166	-	14	191	-	66	203	-	54

