

UNIVERSIDAD IBEROAMERICANA

Estudios con Reconocimiento de Validez Oficial por Decreto Presidencial de 3 de Abril de 1981



“ESTIMACIÓN DE LOS MODELOS DE ECUACIONES
ESTRUCTURALES, DEL ÍNDICE MEXICANO DE LA SATISFACCIÓN
DEL USUARIO DE PROGRAMAS SOCIALES MEXICANOS, CON LA
METODOLOGÍA DE MÍNIMOS CUADRADOS PARCIALES”

TESIS

Que para obtener el grado de

MAESTRA EN INGENIERIA DE CALIDAD

Presenta

MARÍA ELENA GÓMEZ CRUZ

Director: Dra. Odette Lobato Calleros

Lectores: Mtro. Hugo Serrato González
Dr. Primitivo Reyes Aguilar

México, D.F.

2011

ÍNDICE TEMÁTICO

INTRODUCCIÓN	11
1. CAPÍTULO	17
Introducción a los Modelos de Ecuaciones Estructurales (SEM)	17
1.1 Introducción	17
1.2 Conceptos Fundamentales	18
1.3 Técnicas estadísticas para el análisis de Modelos de Ecuaciones Estructurales	20
1.3.1 Análisis de Senderos (Path Analysis)	21
1.3.2 Análisis Componentes Principales	32
1.3.3 Análisis Factorial	37
1.3.4 Modelo de Ecuaciones Estructurales (SEM)	44
1.4 Conclusiones	48
2. CAPÍTULO	50
Marco de Referencia. Índices de Satisfacción	50
2.1 Introducción	50
2.2 Índices Nacionales de Satisfacción	51
2.1.1 Barómetro Sueco (SCBS)	54
2.1.2 American Customer Satisfaction Index (ACSI)	56
2.1.3 European Customer Satisfaction Index (ECSI)	62
2.1.4 Índice de Satisfacción del Consumidor en Hong Kong (HKCSI)	66
2.2 Índice Mexicano de Satisfacción de los Usuarios (IMSU)	71
2.2.1 Programa de Abasto Rural. Diconsa	73
2.1.1 Programa de Desarrollo Local. Microrregiones	74
2.3 Estudio de Satisfacción Programa de Abasto Rural Diconsa. Universidad Veracruzana	77
2.2 Conclusiones	81

3. CAPÍTULO 83

Marco Teórico. Estimación de Modelos de Ecuaciones Estructurales 83

3.1	Introducción	83
3.2	Indicadores en el Modelo de Medida	83
3.2.1	Indicador Reflexivo	84
3.2.2	Indicador Formativo	87
3.3	Enfoques para la Estimación de Modelos de Ecuaciones Estructurales	91
3.3.1	Estimación de SEM con el enfoque de covarianzas	94
3.3.1.1	Tamaño de muestra	99
3.3.1.2	Índices de Ajuste	100
3.3.2	Estimación del SEM con el enfoque de varianzas (PLS).	103
3.3.2.1	Operación del método	105
3.3.2.2	Características del método	111
3.3.2.3	Tamaño muestral	115
3.3.2.4	Interpretación de resultados	116
3.3.2.5	Conclusiones	133

4. CAPÍTULO 136

Aplicación 136

4.1	Introducción	136
4.2	Aplicación	136
4.3	Análisis de Resultados	138
4.3.1	Primera estimación con SmartPLS	139
4.3.1.1	Modelo de Medida	139
4.3.1.2	Modelo Estructural	145
4.3.2	Segunda estimación con SmartPLS	149
4.3.2.1	Modelo de Medida	149
4.3.2.2	Modelo Estructural	152

4.3.3	Estimación con ACSI	154
4.3.3.1	Modelo de Medida	155
4.3.3.2	Modelo Estructural	157
4.4	Conclusiones	160
CONCLUSIONES Y RECOMENDACIONES		162
5. BIBLIOGRAFÍA		164

ÍNDICE DE FIGURAS

FIGURA 1-1	ANÁLISIS FACTORIAL EXPLORATORIO	42
FIGURA 1-2	ANÁLISIS FACTORIAL CONFIRMATORIO	43
FIGURA 2-1	BARÓMETRO SUECO: DIAGRAMA DE TRAYECTORIAS	55
FIGURA 2-2	BARÓMETRO SUECO: RELACIONES ENTRE FACTORES MANIFIESTOS Y LATENTES	55
FIGURA 2-3	ACSI SECTOR PRIVADO: DIAGRAMA DE TRAYECTORIAS	58
FIGURA 2-4	ACSI SECTOR PRIVADO: VARIABLES MANIFIESTAS Y SU RELACIÓN CON LAS LATENTES	59
FIGURA 2-6	ACSI SECTOR PÚBLICO: COEFICIENTES DE REGRESIÓN	61
FIGURA 2-5	ACSI: DIAGRAMA DE TRAYECTORIAS PARA EL CASO DE SECTOR PÚBLICO	60
FIGURA 2-7	ECSI: DIAGRAMA DE TRAYECTORIAS	64
FIGURA 2-8	ECSI: VARIABLES LATENTES Y SUS RELACIONES	64
FIGURA 2-9	MODELO HKCSI: DIAGRAMA DE TRAYECTORIA	68
FIGURA 2-10	MODELO IMSU SECTOR PÚBLICO	72
FIGURA 2-11	MODELO DE CAUSALIDAD COMPLETO ISBN1	78
FIGURA 2-12	MODELO DE CAUSALIDAD COMPLETO ISBN2. BASADO EN ECSI	79
FIGURA 2-13	MODELO DE CAUSALIDAD COMPLETA ISBN3. BASADO EN ACSI	80
FIGURA 3-1	INDICADOR REFLEXIVO DE MEDIDA	85
FIGURA 3-2	INDICADOR FORMATIVO DE MEDIDA	88

FIGURA 3-3 MODELO MIMIC	91
FIGURA 3-4 ETAPAS DE ELABORACIÓN SEM	98
FIGURA 3-5 DIAGRAMA DE FLUJO DE SELECCIÓN DE TÉCNICA SEM	135
FIGURA 4-1 MODELO IMSU PAS LICONSA LÍQUIDA	138
FIGURA 4-2 MODELO IMSU PAS LICONSA LÍQUIDA, SMARTPLS	148
FIGURA 4-3 MODELO IMSU PAS LICONSA LÍQUIDA, SMARTPLS	154
FIGURA 4-4 MODELO IMSU PAS LICONSA LÍQUIDA, ACSI	159

ÍNDICE DE TABLAS

TABLA 1-1 CORRELACIONES PARA EL MODELO PROPUESTO	29
TABLA 2-1 BARÓMETRO SUECO. VARIABLES MANIFIESTAS	56
TABLA 2-2 ACSI. VARIABLES MANIFIESTAS	62
TABLA 2-3 ECSI. VARIABLES MANIFIESTAS	66
TABLA 2-4 HKCSI. VARIABLES MANIFIESTAS	71
TABLA 2-5 IMSU-DICONSA. VARIABLES MANIFIESTAS	75
TABLA 2-6 IMSU-MICRORREGIONES. VARIABLES MANIFIESTAS	76
TABLA 2-7 UNIVERSIDAD VERACRUZANA. VARIABLES MANIFIESTAS	81
TABLA 4-1 PESOS EXTERNOS MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	141
TABLA 4-2 CONSISTENCIA INTERNA DE INDICADORES DEL MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	142
TABLA 4-3 AVE VARIABLES LATENTES MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	143
TABLA 4-4 CORRELACIONES VARIABLES LATENTES MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	144

TABLA 4-5 PESOS CRUZADOS MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	144
TABLA 4-6 R ² DE LAS VARIABLES LATENTES ENDÓGENA. SMARTPLS	145
TABLA 4-7 BOOTSTRAP CON 500 MUESTRAS DE 1000 CASOS. SMARTPLS	146
TABLA 4-8 BLINDFOLDING G=7, OBTENIDO EN SMARTPLS	147
TABLA 4-9 PESOS EXTERNOS MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	149
TABLA 4-10 CONSISTENCIA INTERNA DE LOS INDICADORES MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	150
TABLA 4-11 AVE VARIABLES LATENTES MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	150
TABLA 4-12 CORRELACIONES VARIABLES LATENTES MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	151
TABLA 4-13 PESOS CRUZADOS MODELO PAS-LICONSA LÍQUIDA. SMARTPLS	151
TABLA 4-14 R ² DE LAS VARIABLES LATENTES ENDÓGENAS. SMARTPLS	152
TABLA 4-15 BOOTSTRAP CON 500 MUESTRAS DE 1000 CASOS. SMARTPLS	152
TABLA 4-16 BLINDFOLDING G=7, OBTENIDO EN SMARTPLS	153
TABLA 4-17 PESOS EXTERNOS ESTIMADOS CON ACSI	155
TABLA 4-18 ALFA DE CRONBACH ESTIMADO CON ACSI	156
TABLA 4-19 VALORES PROPIOS DE LAS VARIABLES LATENTES	156
TABLA 4-20 COMUNALIDAD DE LAS VARIABLES LATENTES ESTIMADA CON ACSI	157
TABLA 4-21 CORRELACIONES ENTRE VARIABLES LATENTES ESTIMADAS EN ACSI	157
TABLA 4-22 DE LAS VARIABLES LATENTES ENDÓGENAS ESTIMADO CON ACSI	158
TABLA 4-23 COEFICIENTES DE SENDEROS ESTANDARIZADOS ESTIMADOS EN ACSI	158

INTRODUCCIÓN

La presente tesis es uno de los resultados del proyecto de investigación “Diseño y Aplicación de una Metodología para el Establecimiento del Índice Mexicano de Satisfacción del Usuario de Programas Sociales Mexicanos” (IMSU-PSM), proyecto financiado por el Fondo Sectorial Sedesol-Conacyt. Este proyecto lo desarrolla un grupo interdisciplinario de investigadores y estudiante de la Universidad Iberoamericana-Ciudad de México, siendo su responsable técnica la Dra. Odette Lobato. Los avances y resultados del proyecto son evaluados por el Consejo Técnico conformado por prestigiados investigadores de diversas universidades mexicanas.

El establecimiento del Índice Mexicano de Satisfacción del Usuario de Programas Sociales Mexicanos incluye las siguientes etapas: i) análisis de la información existente respecto a los programas sociales a ser evaluados -objetivos y procesos- y de sus beneficiarios - características educacionales, económicas y sociales-, ii) dominio del estado del arte sobre el tema de los modelos estructurales sobre la satisfacción de usuarios y los indicadores nacionales, iii) desarrollo de estudio cualitativo sobre las preferencias de los usuarios, iv) diseño de un modelo de ecuaciones estructurales sobre la satisfacción que incluye causas y efectos, vi) diseño del instrumento de medición sobre las variables del modelo estructural, vii) desarrollo de prueba piloto, viii) obtención de diseño muestral, ix) aplicación de encuestas, x) estimación del modelo de ecuaciones estructurales, xi) obtención de resultados de satisfacción, sus causas y resultados, xii) evaluación, de los resultados obtenidos, por el Consejo Técnico.

El objetivo de la tesis es contribuir al establecimiento del Índice Mexicano de Satisfacción del Usuario de Programas Sociales Mexicanos mediante la identificación y puesta a prueba del método estadístico, Mínimos Cuadrados Parciales, para la estimación de los modelos de ecuaciones estructurales de la satisfacción de los usuarios.

La relevancia de la tesis se encuentra en la dificultad que implica la estimación de la variable *satisfacción* respecto a servicios y a la forma en que los usuarios los perciben.

Huerta (2011, 13) cita las características de los servicios: Intangibles (Bateson, 1977); Heterogéneos (Booms & Biter 1981); Inseparable su generación y entrega (Carman & Langeard 1980); Perecederos (Grönroos 1990).

Ruiz-Olalla (citado en Huerta 2011, 14) señala como rasgos de la percepción de los usuarios:

- a) La dificultad de valorar la calidad de los bienes tangibles
- b) La influencia de las expectativas en la valoración
- c) La evaluación abarca tanto una evaluación global del servicio, como el proceso a través del cual se recibió

La *satisfacción* por ser una variable no observable que depende de otras es resultante de la relación entre variables no observables (latentes), que para su medición se valen de variables observables (manifiestas). Finalmente, la satisfacción se ve reflejada en acciones, positivas y negativas, deseables de ser medidas.

Las hipótesis planteadas por los investigadores sobre la evaluación de la satisfacción, las variables latentes propuestas y su interacción, se plasman en el modelo de ecuaciones

estructurales propuesto. Con determinadas metodologías, el modelo propuesto es puesto a prueba y evaluado en su nivel de ajuste, es decir, en qué medida el fenómeno estudiado se comporta o no como se propuso. Otras metodologías permiten análisis exploratorio y, en cierta medida, confirmatorio del modelo.

Los métodos usados para medir la satisfacción, deben cumplir con características como: operar y distinguir variables latentes y variables manifiestas; calcular el valor de las variables latentes; evaluar relaciones de dependencia múltiple y cruzada entre variables; evaluar la importancia relativa de cada predictor; probar hipótesis referentes al nivel de ajuste del modelo propuesto; evaluar la significación de las relaciones entre las variables.

Existen varias técnicas estadísticas que satisfacen alguna o algunas de las características antes mencionadas, tales como: Regresión Múltiple, Análisis de Discriminante, Análisis de Varianza, Regresión Logística, así como Análisis Factorial y Análisis Clusters. Haenlein (2004, 283-284) subraya que estos instrumentos estadísticos muestran limitaciones tales como a) la postulación de un modelo estructural simple, b) el supuesto de que todas las variables deben ser consideradas como observables y c) la conjetura de que todas las variables son medidas sin error. Sobre la primera limitación, argumenta que vivimos en un mundo multivariado y complejo, de manera que realizar estudios considerando una o dos variables aisladas es relativamente irreal e inconsecuente. Sobre la segunda limitación se indica que sólo las variables obtenidas por medio de experimento muestral real son variables observables, de otra manera deben ser consideradas inobservables. Finalmente sobre la tercera limitación, señala que observaciones del mundo real van acompañadas por un error de medida, ya sea: i) aleatorio (causado por el orden de las preguntas o un encuestador cansado);

ii) error sistemático (varianza atribuido por el método de medida y no al constructo de interés).

La descripción de los modelos de ecuaciones estructurales, mostrará que esta metodología cumple con las características requeridas para la evaluación del fenómeno *satisfacción*.

Los modelos de ecuaciones estructurales retoman elementos de técnicas como Análisis de Senderos, Análisis Factorial así como Regresión Múltiple. Su modelo de medida y su modelo estructural, los hacen más robustos que la utilización por separado de las técnicas antes mencionadas.

La literatura establece que una de las características más relevantes de los modelos de ecuaciones estructurales es la identificación del modelo, que especifica relaciones entre variables así como la direccionalidad de causalidad. La identificación del modelo requiere de varias características; aceptación teórica del modelo, eliminación de modelos equivalentes, indicadores aceptables del modelo y replicación de los resultados con muestras independientes.

El *Índice Mexicano de Satisfacción de Usuarios Programas Sociales Mexicanos* se basa en el modelo de satisfacción para el sector público, desarrollado por el *American Customer Satisfaction Index*. La evaluación de la satisfacción se realiza a través de un modelo de ecuaciones estructurales desarrollado explícitamente para ello. Los principales enfoques para la evaluación de modelos estructurales son: el enfoque de varianza y el enfoque de covarianzas. En general los índices de satisfacción internacionales utilizan el enfoque de

varianzas, por las características de los datos y modelos. Los análisis de este trabajo también se hacen bajo ese enfoque.

Varios son los índices de satisfacción desarrollados en el mundo bajo esta metodología. En general los modelos de satisfacción consideran la satisfacción general, confirmación de las expectativas, comparación del rendimiento del producto y el concepto ideal del consumidor.

En el primer capítulo se ha dispuesto mostrar los conceptos utilizados en los modelos estructurales y a los que se hará referencia en el resto de los capítulos. También se han expuesto brevemente características de técnicas estadísticas inmiscuidas en los Modelos de Ecuaciones Estructurales, tales como Análisis de Senderos, Análisis Factorial y Componentes Principales, lo cual facilitará la exposición de resto del trabajo.

En el segundo capítulo se muestran algunos modelos de satisfacción internacionales, así como los indicadores correspondientes a cada constructo y sus relaciones causales. También se comentan los estudios de satisfacción bajo esta metodología, del sector público, realizados hasta el momento en México.

La descripción de la metodología, las características del enfoque de varianzas y covarianzas, indicadores de medida formativos y reflexivos, ventajas y desventajas de cada enfoque, operación del método, indicadores de bondad de ajuste, criterios para la lectura de resultados y tamaño de muestra, se describen en el capítulo 3.

En el capítulo 4 se muestran los resultados y análisis de la evaluación de satisfacción de los beneficiarios del PAS-Liconsa líquida. Para la estimación se consideró el enfoque de

varianzas y se utilizaron dos software, el diseñado por *American Customer Satisfaction Index* y el SmartPLS. Se realiza el análisis estadístico para el modelo de medida y el modelo estructural, se muestran las similitudes y diferencias obtenidas. Para la estimación realizada con SmartPLS, se especifica el tipo de tratamiento para los valores perdidos, el esquema de ponderación utilizado en el modelo interno o estructural, así como el cambio de signo para el proceso de re muestreo *bootstrap*.

Finamente se muestran conclusiones y recomendaciones para próximos estudios.

1. Capítulo

Introducción a los Modelos de Ecuaciones Estructurales (SEM)

1.1 Introducción

Con el objeto de comprender el origen, la operación y la aplicación de los Modelos de Ecuaciones Estructurales (SEM por sus siglas en inglés)¹, en este capítulo se muestra la definición de conceptos clave, la nomenclatura aceptada, técnicas estadísticas ligadas a los SEM y algunos ejemplos numéricos. De forma inductiva se busca mostrar como técnicas, tales como el Análisis de Senderos y el Análisis Factorial, integran a los SEM.

Como podrá constatarse los SEM o de regresión estructural, están conformados por un modelo de medida y un modelo estructural, elementos que se detallan adelante. El modelo de medida obedece las reglas del Análisis de Factores (en el caso reflexivo).

El subtema correspondientes a Componentes Principales se retomará al presentar el método de estimación a utilizar: Mínimos Cuadrados Parciales (PLS por sus siglas en inglés)².

“La técnica de modelado de ecuaciones estructurales se considera una extensión de varias técnicas multivariantes como la regresión múltiple, el análisis factorial principalmente y el análisis de senderos” (Fernández 2004, 218). Los SEM han sido utilizados, sobre todo en el campo de las ciencias sociales, debido a que realiza mediciones de variables no observables, a partir de variables observables, además de analizar relaciones entre variables latentes.

¹ Modelos de Ecuaciones Estructurales, de aquí en adelante SEM .

² Mínimos Cuadrados Parciales, de aquí en adelante PLS.

1.2 Conceptos Fundamentales

En párrafos anteriores se ha hecho referencia a las variables latentes y manifiestas. A continuación se detalla su definición y los símbolos con los que se representan en SEM. Para esta exposición me baso en el libro de Rex B. Kline (2005) y en Manzano (2001).

Las *variables manifiestas u observables*, son aquellas que se miden directamente. Para Dijkstra (1983, 283 citado en Haenlein 2004, 284) “una variable puede ser llamada observable si y sólo si su valor es obtenido por medio de un experimento muestral real”. Su representación es a través de cuadrados o rectángulos. En general se les asignan las letras X y Y.



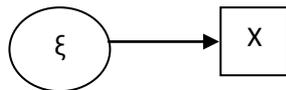
Las *variables latentes o no observables*, son aquellas que no pueden ser medidas directamente.

Siguiendo la definición de Dijkstra, mostrada en el párrafo anterior, “Por lo tanto, cualquier variable que no corresponda directamente a algo observable debe ser considerada como no observable”. Es posible decir que se trata de variables abstractas, que representan conceptos unidimensionales. Como las variables latentes corresponden a conceptos, son variables hipotéticas que varían en su grado de abstracción. Inteligencia, clase social, poder y expectativas, son variables latentes abstractas creadas en la teoría.

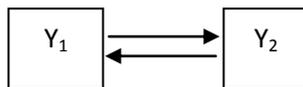
Las variables latentes requieren ser medidas a través de variables observadas. Para su representación se utilizan círculos o elipses. En general se determinan con las letras griegas ξ y η , según su función en el modelo exógena o endógena respectivamente.



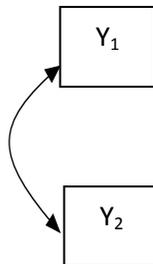
Las *relaciones entre variables* se determinan con flechas. Las flechas unidireccionales representan la hipótesis de un efecto directo de una variable sobre otra. El origen de la flecha indica la causa y la punta señala el efecto.



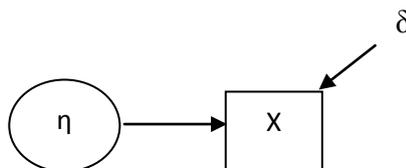
Existen *relaciones recíprocas* entre las variables, en este caso la relación se representa con dos flechas.



La *correlación* entre dos variables se representa con una flecha curva bidireccional.



Los *errores* se representan como variables y se indica su relación con la variable. Teóricamente los errores representan todas las causas de una variable que son omitidas. Los errores son variables latentes.



Variable exógena o independiente o regresor o predictor es aquella cuyas causas son desconocidas. Son determinadas fuera del modelo para que influyan en el comportamiento de

las variables endógenas. En los SEM se identifican porque no reciben impactos, sólo salen flechas.

Variable endógena, dependiente o criterio, en general, y con base en el modelo econométrico, se caracteriza por ser explicada por el funcionamiento del modelo. Las variables endógenas son explicadas por las variables exógenas propuestas. En los SEM se identifican por recibir impactos de otras variables.

En SEM es posible que una variable tenga doble función, como endógena y exógena. A esta doble función se le conoce como efecto indirecto o mediador.

1.3 Técnicas estadísticas para el análisis de Modelos de Ecuaciones Estructurales

En este apartado se describen brevemente los enfoques para la estimación de SEM y técnicas multivariantes en las que se basan. Para la estimación de SEM se tienen dos enfoques: 1) SEM basados en covarianzas y 2) SEM basados en componentes. A este último también se le conoce como basado en varianzas. El trabajo presentado en esta tesis sigue el segundo enfoque, por lo que los elementos en los que se basa la primera sólo se mencionan. Este punto será abordado en el Capítulo 3.

El enfoque basado en covarianzas desarrollada alrededor de Karl Jöreskog, es considerado una generalización del Modelo de Senderos, Análisis de Componentes Principales y Análisis de Factores. El segundo enfoque basado en varianzas (también conocido como componentes), desarrollado alrededor de Herman Wold bajo el nombre de PLS (Partial Least Squares),

puede ser considerado como una generalización de Análisis de Componentes Principales (Tenenhaus 2008, 1).

1.3.1 Análisis de Senderos (Path Analysis)

El Análisis de Senderos (Path Analysis) es el modelo más utilizado para verificar y apoyar conjuntos de supuestos causales entre variables que se dan en un estudio. El objetivo es explicar las variables dependientes y la relación entre ellas. Se consideran sólo variables observables. Existe una medida individual para cada variable y el investigador tiene una hipótesis sobre la relación entre las variables. Las variables dependientes tienen asociado un error aleatorio llamado disturbio. “Los disturbios son análogos a los residuales en regresión, pero tienen una connotación más basada en un modelo causal que en un modelo de predicción. Teóricamente los disturbios representan todas las causas de variables endógenas que son omitidas en el modelo estructural” (Kline 2005, 69).

Si el modelo construido por el investigador se ajusta a los datos recogidos, el modelo se mantiene con el fin de ser sometido a nuevas pruebas o bien, para modificarlo o reemplazarlo. Pero en todo caso, el análisis de senderos no es un procedimiento para demostrar la existencia de causalidad en forma definitiva.

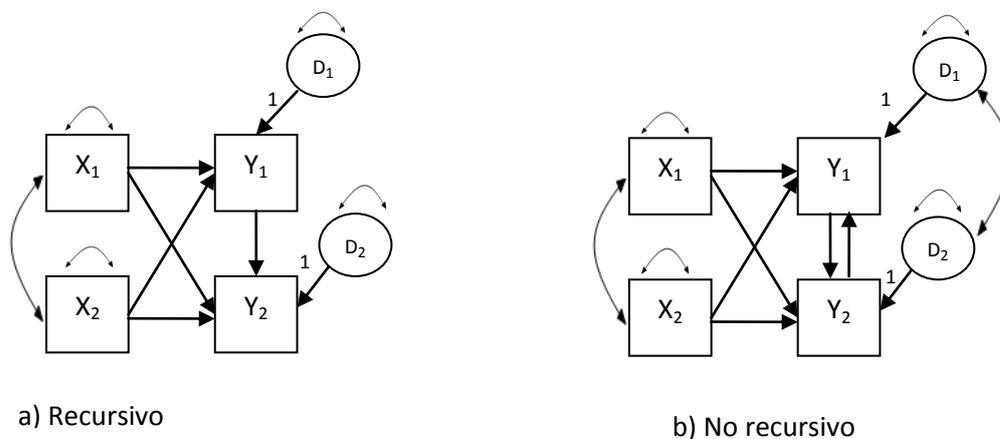
El análisis de senderos se inicia con un diagrama basado en una teoría, en el cual se señalan las relaciones de influencias sobre las variables. Se busca validar o no la hipótesis expuesta en la estructura causal, así como evaluar el peso de cada relación, a través de los llamados coeficientes de sendero. Es de relativa importancia la correcta especificación³ y

³ La especificación del modelo se refiere a que las hipótesis del investigador estén expresadas en el modelo estructural. En el caso de métodos de información completa, como es el caso de Máxima Verosimilitud, los errores de especificación se propagan en todo el modelo (Kline 2005, 63. 115).

direccionalidad del modelo, las cuales son explícitamente determinadas por los investigadores, así como de la realización de estudios cualitativos del fenómeno.

Los modelos de senderos se pueden clasificar en recursivos y no recursivos. En los recursivos los disturbios no están correlacionados y todos los efectos causales son unidireccionales. Los no recursivos tienen causalidad recíproca y los disturbios pueden estar correlacionados.

Ejemplo tomado de (Kline 2005, 103).



Fuente: Kline (2005: 103)

Figura 1-1 Ejemplo de Modelo de Senderos recursivo y no recursivo

Las variables exógenas en ambos modelos son X_1 y X_2 y las variables endógenas son Y_1 y Y_2 . En el modelo recursivo la variable Y_1 es causa de la variable Y_2 , mientras que en el modelo no recursivo, las variables endógenas son causa y efectos entre ellas. También se observa que en el modelo no recursivo los disturbios pueden estar correlacionados entre sí, mientras que en el modelo recursivo no. La correlación entre las variables exógenas está indicada por la flecha bidireccional, y cuando está sobre una variable exógena indica su varianza. Los números uno, asignados a los coeficientes de senderos entre los disturbios y la variables endógenas, indican que ese sendero tiene un parámetro fijo, el cual no deberá estimarse. Esto se hace generalmente para reducir el número de parámetros a estimar y lograr

un modelo determinado teóricamente, además de proporcionar una escala a la variable. Este tipo de estructura es utilizado en los modelos bajo el enfoque de covarianzas.

Comento brevemente los efectos directos, indirectos y totales, así como los coeficientes de senderos y su interpretación. Para ello me centro en el modelo recursivo de la Figura 1-1. Las ecuaciones que determinan las variables endógenas son:

$$Y_1 = P_{Y_1X_1}X_1 + P_{Y_1X_2}X_2 + d_1 \quad (1.4.1.1)$$

$$Y_2 = P_{Y_2X_2}X_2 + P_{Y_2X_1}X_1 + P_{Y_2Y_1}Y_1 + d_2 \quad (1.4.1.2)$$

Los coeficientes de regresión estandarizados son los coeficientes de senderos $P_{Y_1X_1}$, $P_{Y_1X_2}$, $P_{Y_2X_1}$, $P_{Y_2X_2}$ y $P_{Y_2Y_1}$. Su significado e interpretación es el mismo que en la regresión múltiple. Es decir, en la ecuación (1.4.1.1) un aumento en una desviación estándar en X_1 produce cambio de $P_{Y_1X_1}$ desviaciones estándar en Y_1 . Si los coeficientes no están estandarizados, entonces $P_{Y_1X_1}$ es el cambio que experimenta Y_1 al aumentar X_1 en una unidad.

En cada modelo de regresión, los estimadores de los coeficientes de senderos se obtienen de manera usual por mínimos cuadrados en cada una de las regresiones, lo cual genera las ecuaciones normales del modelo que equivale a una descomposición de los coeficientes de correlación. Para el caso de la Figura 1-1 a) las ecuaciones normales son:

$$\left. \begin{aligned} r_{Y_1X_1} &= P_{Y_1X_1} + r_{X_1X_2}P_{Y_1X_2} \\ r_{Y_1X_2} &= P_{Y_1X_2} + r_{X_1X_2}P_{Y_1X_1} \end{aligned} \right\} \text{EN}_1$$

$$\left. \begin{aligned} r_{Y_2X_2} &= P_{Y_2X_2} + r_{X_1X_2}P_{Y_2X_1} + r_{Y_1X_2}P_{Y_2Y_1} \\ r_{Y_2X_1} &= P_{Y_2X_1} + r_{X_1X_2}P_{Y_2X_2} + r_{Y_1X_1}P_{Y_2Y_1} \end{aligned} \right\} \text{EN}_2$$

$$r_{Y_2Y_1} = P_{Y_2Y_1} + r_{Y_1X_1}P_{Y_2X_1} + r_{Y_1X_2}P_{Y_2X_2}$$

En donde los coeficientes de correlación se obtienen en términos de los coeficientes de senderos y otras correlaciones. Para el caso de las variables exógenas X_1 y X_2 , no se descompone su correlación. Como puede observarse, la correlación entre las variables Y_1 y X_1 es $P_{Y_1X_1}$, de manera que todas las correlaciones pueden ser expresadas en términos de los coeficientes de senderos. Para ello hay que considerar todos los senderos por los cuales se pueden comunicar el par de variables. Una correlación se descompone en la suma de productos de coeficientes de cada sendero que conecta a las variables analizadas. En la obtención de las correlaciones los disturbios se desprecian por no estar correlacionados con otras variables. La Figura 1-2 muestra gráficamente la descomposición de la correlación entre

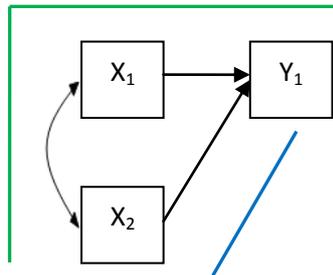


Figura 1-2 Ejemplo descomposición de correlaciones

Las variables Y_1 y X_2 .

Como se indicó, la correlación entre Y_1 y X_2 , está determinada por la suma del producto de los coeficientes de senderos que conectan a las variables, en este caso los dos senderos que conectan a las variables son señalados con color verde y azul. De manera que la correlación se descompone como sigue:

$$r_{Y_1 X_2} = \underbrace{P_{Y_1 X_2}}_{\text{ET}} + \underbrace{r_{X_1 X_2}}_{\text{ED}} \underbrace{P_{Y_1 X_1}}_{\text{EI}}$$

En esta descomposición, la correlación $r_{Y_1 X_2}$ es el efecto total (ET) entre las variables Y_1 y X_2 , $P_{Y_1 X_2}$ es el efecto directo (ED) y $r_{X_1 X_2} P_{Y_1 X_1}$ es el efecto indirecto (EI).

Los supuestos del diagrama de senderos son:

1. La correlación entre las variables residuales y las variables exógenas es nula. Lo anterior debido al requerimiento estadístico usado en regresión, en donde se indica que los predictores no deben estar correlacionados con los errores. Además de asumir, conceptualmente, independencia entre las variables exógenas y los disturbios permite la estimación de efectos directos.
2. La causalidad puede ser no recursiva.
3. Las correlaciones entre las variables son lineales y aditivas, es decir, se excluyen relaciones curvilíneas y de interacción multiplicativa.

En la Figura 1-1 se ejemplifica un Análisis de Senderos

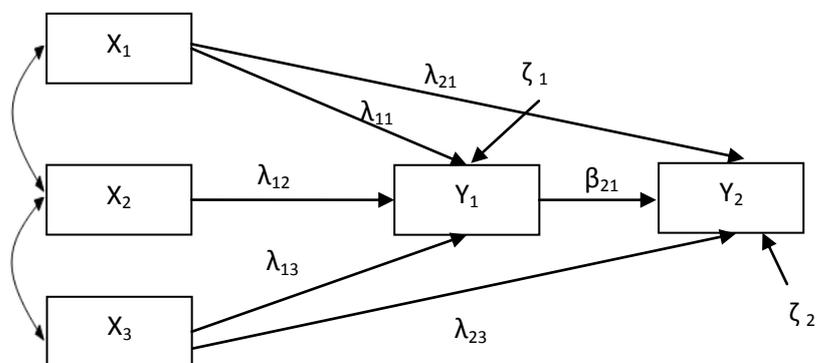


Figura 1-3 Análisis de Senderos

En el diagrama, las variables X_1 , X_2 y X_3 son exógenas y las variables Y_1 y Y_2 son endógenas. Una característica esencial de las variables endógenas, es que pueden tomar el lugar de dependientes y posteriormente de independientes. Las letras griegas λ_{ij} sobre las flechas representan los coeficientes de sendero a estimar, los cuales determinan la relación causal entre una variable exógena y una variable endógena. La regla para colocar los subíndices es colocar en primer término el subíndice de la variable efecto (endógena) y posteriormente el subíndice de la variable causa (exógena). Los coeficientes de senderos entre variables exógenas se denotan con la letra griega β , con la misma regla para los subíndices. Las variables ζ son los disturbios e indican el efecto de variable no incluidas en el modelo, tal como se comentó anteriormente.

Un modelo de Análisis de Senderos se representa matemáticamente con la ecuación siguiente:

$$Y = BY + \Gamma X + \zeta$$

Donde

X = vector de $p \times 1$ de variables observadas independientes

Y = vector de $p \times 1$ de variables observadas dependientes

B = matriz de $p \times p$ de coeficientes correspondientes a Y

Γ = matriz de $p \times p$ de coeficientes correspondientes a X

ζ = vector de $p \times 1$ de disturbios

Realizar el análisis de este modelo con regresiones separadas, no consideraría las interrelaciones entre variables dependientes. “La técnica de correlación canónica analiza simultáneamente un conjunto de variables exógenas o endógenas múltiples y controla las

interacciones entre cada conjunto, sin embargo las variables Y_1 y Y_2 deben ser especificadas como endógenas o exógenas, no ambas” (Kline 2005, 67).

Un elemento que debe ser considerado para la correcta evaluación de un Análisis de Senderos, en SEM basados en covarianzas, es la identificación del modelo. Para que el modelo este identificado se requiere que: 1) el número de parámetros a estimar sea menor o igual al número de observaciones, considerando las observaciones como el número de varianzas y covarianzas generadas por las variables observables del modelo. Si el número de variables observables es v , el número de observaciones es $v(v+1)/2$; 2) cada variable latente este asignada a una escala métrica. El requerimiento de que haya al menos tantas observaciones como parámetros a estimar, se puede expresar como $df_M \geq 0$, donde df_M son los grados de libertad del modelo (Kline 2005, 105).

En la identificación del modelo hay tres casos:

- a) Modelos sub identificados: menos observaciones que parámetros, por lo tanto no hay una solución
- b) Modelos saturados: igual número de observaciones que parámetros, Hay una solución única. El nivel de ajuste no se puede evaluar
- c) Modelos sobre-identificados: más observaciones que parámetros. Hay infinitas soluciones, se busca aquella que es óptima según el criterio. Se puede evaluar el grado de ajuste de los datos al modelo

El modelo presentado en la Figura 1-1 a) está identificado, puesto que el número de variables observadas es 5, con $4(5)/2=10$ observaciones. Los parámetros por estimar son 10 (5 coeficientes de sendero, 4 varianzas y 1 covarianza). Como puede observarse, el número de

estimaciones permanece igual sin importar el tamaño de la muestra. En el Cap. 3 se mencionarán líneas manejadas en la literatura para el establecimiento del tamaño de la muestra.

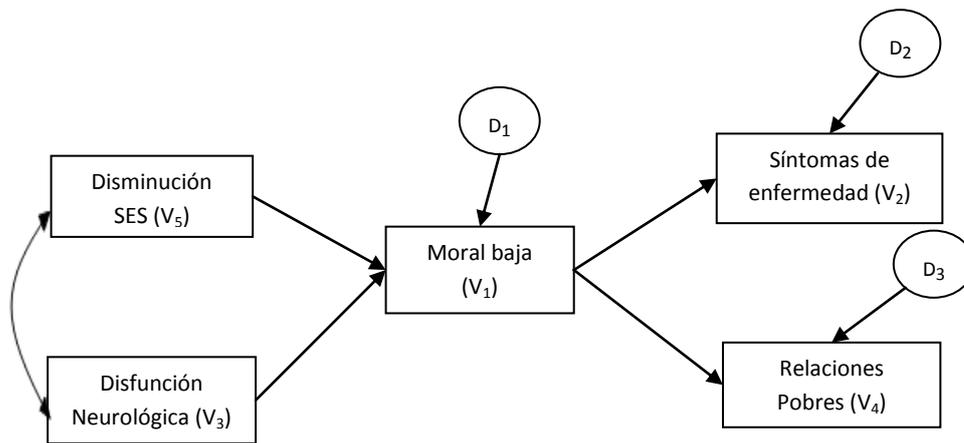
La bondad de ajuste del modelo causal respecto a los datos, se analiza de diferentes formas. Los tres criterios siguientes son comúnmente utilizados para aceptar o rechazar el modelo causal:

1. La magnitud de la variación de las variables dependientes explicadas por las variables independientes del modelo (coeficiente de determinación).
2. Los coeficientes de senderos de mayor tamaño indicarían las variables que deberían incluirse en el modelo.
3. La concordancia entre las relaciones teóricas propuestas y las relaciones estimadas en el modelo.

La estimación de un Análisis de Senderos, hablando propiamente del modelo recursivo, se puede realizar vía regresión múltiple o bien con la rutina de Análisis de Senderos habilitada en programas para SEM. Este último permite la elección entre diferentes métodos de estimación, además de que la estimación de los efectos directos e indirectos es simultánea para el modelo total, mientras que estimar con regresión múltiple implica realizar las regresiones por partes. Otra diferencia importante es el tiempo y trabajo dedicado en cada opción, que como es de esperarse a medida que aumenta la complejidad la segunda opción supera con mucho a la primera.

A continuación se muestra un ejemplo para la comprensión de la operación del Análisis de Senderos. Consiste en un Modelo de Senderos que explica la trayectoria de la recuperación

después de la cirugía cardíaca evaluada por Romney, Jenkins y Bynner (1992). Se presenta el modelo psicosomático sobre la hipótesis de que la moral es un mediador de los efectos de la disfunción neurológica y el estado socioeconómico disminuido (SES). Los efectos de una moral baja propuestos son síntomas físicos de enfermedad y relaciones sociales pobres.



Fuente: Romney, Jenkins, Bynner (1992, 172)

Figura 1-4 Trayectoria de recuperación después de cirugía cardíaca

	Variable	V ₁	V ₂	V ₃	V ₄	V ₅
V ₁	Moral baja	1				
V ₂	Síntomas de enfermedad	0.53	1			
V ₃	Disfunción neurológica	0.15	0.18	1		
V ₄	Relaciones pobres	0.52	0.29	-0.05	1	
V ₅	Disminución SES	0.30	0.34	0.23	0.09	1

Tabla 1-1 Correlaciones para el modelo propuesto

Para este modelo se presentan a continuación las tres ecuaciones de regresión así como sus respectivas ecuaciones normales.

$$V_1 = P_{V_1V_5}V_5 + P_{V_1V_3}V_3 + \varepsilon \quad (1.4.1.3)$$

Ecuaciones Normales

$$P_{V_1V_5} + P_{V_1V_3}r_{V_5V_3} = r_{V_1V_5}$$

$$P_{V_1V_5}r_{V_5V_3} + P_{V_1V_3} = r_{V_1V_3}$$

$$V_2 = P_{V_2V_1}V_1 + \varepsilon \quad (1.4.1.4)$$

Ecuación Normal

$$r_{V_1V_2} = P_{V_2V_1}$$

$$V_3 = P_{V_4V_1}V_4 + \varepsilon \quad (1.4.1.5)$$

Ecuación Normal

$$r_{V_1V_4} = P_{V_4V_1}$$

Utilizando las correlaciones entre las variables, proporcionadas en la Tabla 1-1 y las ecuaciones normales es posible estimar los coeficientes de senderos manualmente. A continuación se muestra la estimación de los efectos directos $P_{V_1V_5}$ y $P_{V_1V_3}$.

Sustituyendo las correlaciones indicadas en las ecuaciones normales de la ecuación (1.4.1.3)

$$P_{V_1V_5} + 0.23P_{V_1V_3} = 0.30$$

$$0.23P_{V_1V_5} + P_{V_1V_3} = 0.15$$

Resolviendo el sistema

$$P_{V_1V_5} = 0.2803$$

$$P_{V_1V_3} = 0.0855$$

Las ecuaciones de regresión obtenidas, son utilizadas para calcular los residuos, elemento considerado para evaluar el nivel de ajuste del modelo.

La estimación completa para este Análisis de Senderos, se ha realizado con el programa EQS 6.0

En la Figura 1-5 se puede comprobar que la estimación del modelo con un software para la estimación de Modelos de Senderos, coincide con el resultado obtenido con las ecuaciones normales para la estimación de coeficientes de senderos.

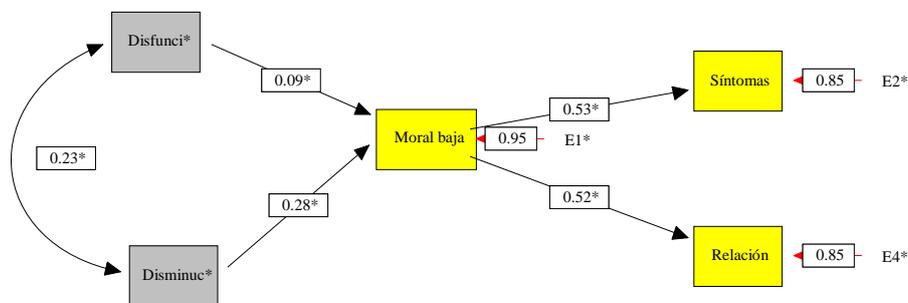


Figura 1-5 Estimación Estandarizada del Modelo Psicosomático

Retomando la ecuación (1.4.1.3) y sustituyendo los coeficientes de senderos estimados, obtenemos que la ecuación para la variable V_1 es:

$$V_1 = 0.28V_5 + 0.09V_3$$

Como se indicó la interpretación de estos coeficientes es la misma que en la regresión múltiple. En este ejemplo en donde se ha proporcionado la matriz de correlaciones, un incremento de una desviación estándar en V_5 produce un incremento de 0.28 desviaciones estándar en V_1 , de la misma manera un incremento de una desviación estándar en V_3 genera un incremento de 0.09 desviaciones estándar en V_1 .

1.3.2 Análisis Componentes Principales

Para la exposición de esta sección y la siguiente me baso en el capítulo 5 del libro, *Multivariate Statistical Methods*, Manly (1986).

Un problema central en el análisis de datos multivariados es la reducción de la dimensión. Es deseable describir con precisión los valores de p variables con un subconjunto pequeño de ellas $r < p$, de manera que se reduzca la dimensión a costa de una pequeña pérdida de información.

El *análisis de componentes principales*, es uno de los métodos multivariados más simples. Su objetivo es tomar p variables X_1, X_2, \dots, X_p y encontrar la combinación de estas para producir índices (que pueden ser consideradas variables latentes) Z_1, Z_2, \dots, Z_p que no estén correlacionados. La no correlación indica que los índices miden diferentes dimensiones en los datos. Es deseable que los datos estén descritos por un número pequeño de índices, de manera que haya una reducción en la dimensión, esto ocurre cuando las variables originales están altamente correlacionadas. Esta técnica es debida a Hotelling (1933), aunque sus orígenes se

encuentran en los ajustes ortogonales por mínimos cuadrados introducidos por K. Pearson (1901 citado en Manly 1986, 59-61).

El desarrollo de esta técnica fue sobre todo en el área de biometría, en donde el número de variables regresoras es muy grande y el número de observaciones pequeño.

La elección de los índices se realiza de tal forma que el primero recoja la mayor proporción posible de la variabilidad original; el segundo índice debe recoger la máxima variabilidad posible no tomada por el primero, y así sucesivamente. Del total de índices se elegirán aquéllos que recojan el porcentaje de variabilidad que se considere suficiente. A éstos se les denomina, precisamente, componentes principales.

La primera componente principal es la combinación lineal de las variables X_1, X_2, \dots, X_p

$$Z_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p$$

Sujetas a la condición de que

$$a_{11}^2 + a_{12}^2 + \dots + a_{1p}^2 = 1$$

Restricción dada para evitar que la $var(Z_1)$ se incremente sólo con incrementar el valor de a_{11} .

El análisis de componentes principales sólo involucra los valores propios (eigen valores o valores característicos) (λ_i) encontrados en la matriz de covarianzas de la muestra. La matriz de covarianzas tiene la siguiente forma:

$$C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1p} \\ c_{21} & c_{22} & \dots & c_{2p} \\ \vdots & \vdots & \dots & \vdots \\ c_{p1} & c_{p2} & \dots & c_{pp} \end{bmatrix}$$

Donde el elemento de la diagonal c_{ii} es la varianza de X_i , y c_{ij} con $i \neq j$ es la covarianza de las variables X_i y X_j . La varianza de los componentes principales son los valores propios de la matriz C . Asumiendo que $\lambda_1 \geq \lambda_2 \geq \dots \lambda_p \geq 0$, entonces λ_i corresponde a la i -ésima componente principal. En particular la $var(Z_i) = \lambda_i$ y las constantes $a_{i1}, a_{i2}, \dots, a_{ip}$ son los elementos correspondientes a los vectores propios (Manly 1986,62-63).

Una propiedad importante de los valores propios es que su suma es igual a la suma de los elementos de la diagonal de la matriz C .

$$\lambda_1 + \lambda_2 + \dots + \lambda_p = c_{11} + c_{22} + \dots + c_{pp}$$

Como c_{ii} es la varianza de X_i y λ_i es la varianza de Z_i , entonces la suma de las varianzas de los componentes principales es igual a la suma de las varianzas correspondiente a las variables originales. De manera que, en ese sentido, las componentes principales cubren toda la variación en los datos originales.

Los pasos para un análisis de componentes principales son:

1. Codificar las variables X_1, X_2, \dots, X_p a tener media cero y varianza uno. No siempre se realiza la estandarización.
2. Calcular la matriz de covarianza C . En el caso de que los datos estén estandarizados es la matriz de correlaciones.
3. Obtener los valores propios $\lambda_1 \geq \lambda_2 \geq \dots \lambda_p$ y los correspondientes vectores propios $a_{i1}, a_{i2}, \dots, a_{ip}$. Los coeficientes del i -ésimo componente principal están dados por a_{ij} , mientras que λ_i es su varianza.
4. Descartar cualquier componente que contenga una pequeña porción de la variación de los datos.

Para que un factor sea fácilmente interpretable debe tener las siguientes características:

- Los coeficientes factoriales deben ser próximos a 1.

- Una variable debe tener coeficientes elevados sólo con un factor.
- No deben existir factores con coeficientes similares.

Un aspecto clave en el análisis de componentes principales es la interpretación de los factores, ya que ésta no viene dada a priori, sino que será deducida tras observar la relación de los pesos con las variables iniciales. De manera que hay que estudiar tanto el signo como la magnitud de las correlaciones, lo cual no siempre es fácil.

Para ilustrar el funcionamiento de Componentes Principales, utilizo los datos obtenidos en la prueba piloto para la medición de la satisfacción de los beneficiarios de programas sociales. Concretamente utilizo los resultados de la encuesta telefónica aplicada a las responsables de estancias infantiles de nueva creación, apoyadas por Sedesol⁴.

Las variables utilizadas son:

P₂ Facilidad del procedimiento de incorporación

P₃ Facilidad para cumplir con los requisitos sobre las instalaciones para iniciar

P₄ Suficiencia sobre la información de derechos y obligaciones

La matriz de correlaciones obtenida con 100 encuestas es:

$$\begin{array}{c}
 \\
 P2 \\
 P3 \\
 P4
 \end{array}
 \begin{array}{ccc}
 P2 & P3 & P4 \\
 \left[\begin{array}{ccc}
 1 & & \\
 0.348 & 1 & \\
 0.265 & 0.521 & 1
 \end{array} \right]
 \end{array}$$

⁴ Lobato O., Rivera H., Serrato H., Golden F., Gómez M.E., Flores C. y Cervantes P. (2010). Reporte Proyecto de Investigación Conacyt-Sedesol-2008-91976: Diseño e Implantación de una Metodología para el Establecimiento del Índice Mexicano de Satisfacción del Usuario de Programas Sociales (IMSU-PS). Avances correspondientes a la primera etapa: principales indicadores nacionales sobre la satisfacción de usuarios, propuesta metodológica para el IMSU-PPS, diseño de la prueba piloto y los hallazgos de la prueba piloto. Universidad Iberoamericana-Cd. de México.

Calculando con Minitab los componentes principales para estas tres variables, se obtiene:

$$Z_1 = 0.493P_2 + 0.631P_3 + 0.599P_4$$

$$Z_2 = 0.854P_2 - 0.222P_3 - 0.470P_4$$

$$Z_3 = -0.164P_2 + 0.744P_3 - 0.648P_4$$

Se muestran los valores propios obtenidos y la proporción de varianza que explican entre paréntesis.

$$\text{var}(Z_1) = \lambda_1 = 1.7677 \quad (0.589)$$

$$\text{var}(Z_2) = \lambda_2 = 0.7635 \quad (0.255)$$

$$\text{var}(Z_3) = \lambda_3 = 0.4688 \quad (0.156)$$

De manera que el componente Z_1 , explica el 58.9% de la varianza y podría interpretarse como el componente que pondera, de manera poco diferenciada, a las tres variables analizadas, asignando mayor peso a la variable P_3 . La segunda componente Z_2 , que explica el 25.5% de la varianza, se puede leer como una comparación entre la variable P_2 y las variables P_3 y P_4 .

Los componentes principales producen índices, los cuales pueden ser considerados como variables latentes, a partir de la combinación lineal entre sus variables. En el ejemplo expuesto, la variable latente Z_1 llamada Condiciones de Acceso causa a las variables manifiestas P_2 , P_3 y P_4 , en la composición que se indica. Este componente reporta el 58.9% de la variación total. Otra característica señalada anteriormente, es que no existe correlación entre los componentes.

El uso de componentes principales es una alternativa en el proceso de obtención de Factores que se describe en la siguiente sección.

Si bien no es del todo claro el uso de componentes principales en los algoritmos en donde se describe la operación del método de mínimos cuadrados parciales para la estimación de SEM, la obtención y análisis de valores propios por constructo es de utilidad para evaluar su unidimensionalidad. En ese sentido se busca que el valor propio correspondiente al primer componente principal sea superior a uno y que el segundo es mucho más pequeño. Unidimensional u homogeneidad es una característica requerida para modelos estructurales cuyo modelo de medida es reflexivo. Estas características son detalladas en el Capítulo 3.

1.3.3 Análisis Factorial

La importancia de presentar brevemente el Análisis Factorial se debe al uso de esta técnica para la estimación del modelo de medida (descrito posteriormente) en los SEM.

El Análisis Factorial tiene objetivos similares al Análisis de Componentes Principales. Busca describir un conjunto de p variables X_1, X_2, \dots, X_p en términos de número menor de indicadores o factores e identificar relaciones entre estas variables. Los factores tienen la función de variables latentes. La principal característica es que el análisis de componentes principales no se basa en un modelo estadístico particular, mientras que el análisis factorial sí. Es decir, en el análisis de componentes se busca hacer un cambio de base con la cual se explique la mayor varianza posible, el análisis factorial involucra, además, variables aleatorias para modelar los errores.

En términos prácticos, el Análisis Factorial es una técnica de reducción de variables explicativas, cuya principal función es encontrar grupos homogéneos de variables a partir de un conjunto numeroso de variables. Esos grupos homogéneos se forman con las variables que están altamente correlacionadas entre sí y procurando, inicialmente, que los grupos sean

independientes. El Análisis Factorial surge impulsado por el interés de Kart Pearson y Charles Spearman en comprender las dimensiones de la inteligencia humana en los años treinta del siglo XX, y muchos de sus avances se han producido en el área de psicometría.

Cuando se recoge un gran número de variables de forma simultánea, es de gran interés averiguar si las preguntas se agrupan de alguna forma característica. Aplicando un análisis factorial, es posible encontrar grupos de variables con significado común y conseguir de esta manera, la reducción en el número de dimensiones.

La idea general del Modelo de Análisis Factorial es

$$X_i = a_{i1}F_1 + a_{i2}F_2 + \dots + a_{im}F_m + e_i \quad (1.4.1)$$

Donde:

X_i es la i -ésima puntuación de la prueba i con media cero y varianza uno.

$a_{i1}, a_{i2}, \dots, a_{im}$ son las cargas de los factores para la i -ésima prueba.

F_1, F_2, \dots, F_m son los m factores comunes no correlacionados, cada uno con media cero y varianza uno.

e_i es el único factor específico a la i -ésima prueba que no está correlacionado con ningún factor común y tiene media cero y varianza uno.

La varianza que está relacionada a los factores comunes es $a_{i1}^2 + a_{i2}^2 + \dots + a_{im}^2$ y recibe el nombre de comunalidad de X_i , donde a_{i1}^2 es la proporción de la varianza de X_i , que es contada por el factor 1.

La $var(e_i)$ es la especificidad de X_i , es decir la parte de la varianza que no está relacionada con los factores comunes.

El Análisis Factorial consta de tres pasos (Manly 1986,74-75):

1. Determinar cargas provisionales de factores a_{ij}

Un camino es, hacer componentes principales utilizando sólo los primeros m . Estos factores no están correlacionados entre ellos ni con los factores específicos. Los factores específicos pueden estar correlacionados entre ellos, sin embargo este punto puede no importar mucho, considerando que las comunalidades son altas.

Cualquier que sea la forma de determinar las cargas de los factores provisionales, es importante señalar que no son únicas. Si F_1, F_2, \dots, F_m son los factores provisionales, la combinación lineal de estos, pueden ser contruidos para no estar correlacionados y explicar bien los datos.

2. Rotación factorial

Los factores provisionales son transformados para encontrar nuevos factores que sean fácilmente interpretables.

3. Cálculo de las puntuaciones de los factores

Esto es, calcular el valor de los factores F_1, F_2, \dots, F_m , para cada uno de los individuos.

Una de las limitaciones del Análisis de Senderos expuesto anteriormente, es el uso de un solo indicador de medida para cada variable observable representada en el modelo. La construcción del modelo de medida utilizado en los SEM requiere formación de constructos

medidos a través de varios indicadores o variables manifiestas, así como el análisis de sus relaciones. Una herramienta que puede apoyar a poner a prueba la conformación de los constructos en investigaciones previas es el Análisis Factorial.

Utilizando los datos presentados en el ejemplo de Componentes Principales, se obtiene el Análisis Factorial con Minitab basado en componentes principales, con un factor.

Sustituyendo la carga de los factores en (1.4.1)

$$P_2 = 0.656F_1 + e_2$$

$$P_3 = 0.839F_1 + e_3$$

$$P_4 = 0.796F_1 + e_4$$

Para este caso a_{12}^2 además de ser la proporción de la varianza explicada por F_1 es la comunalidad de P_2 , puesto que sólo hay un factor.

	Comunalidad
P_2	0.430
P_3	0.703
P_4	0.634

La especificidad de P_2 , está dada por $var(e_i)$, para este caso y considerando valores estandarizados

$$var(P_2) = a_i^2 var(F_1) + var(e_2)$$

De donde

$$var(e_2) = 1 - 0.656^2 = 0.57$$

La varianza de las variables P_2 , P_3 y P_4 explicada por el Factor 1 es 1.767, lo cual equivale al 58.9% de la varianza total.

El cálculo de puntuación de los factores es:

$$F_1 = 0.371P_2 + 0.474P_3 + 0.451P_4$$

Existe una división del Análisis Factorial para evaluar el modelo de medida de los Modelos Estructurales; uno es el llamado Análisis de Factor Confirmatorio y el otro es el Análisis de Factor Exploratorio. A continuación se describen ambos brevemente:

– *Análisis Factorial Exploratorio (EFA)*

Los estudios sobre inteligencia a principios del siglo XX mostraron que existen variables conceptuales que no pueden medirse directamente, por lo que requieren indicadores o variables observables para ser medidos. Conceptos como agresividad, inteligencia, depresión, etc. son algunos de ellos. Esas ideas originaron el Análisis Factorial, el cual en un principio fue sobre todo exploratorio.

Como es sugerido por el título, EFA no requiere hipótesis sobre cómo están relacionados los indicadores de un factor determinado, e incluso el número de factores. Por ejemplo, todos los indicadores están típicamente permitidos para correlacionarse con cualquier factor (Kline 2005, 71).

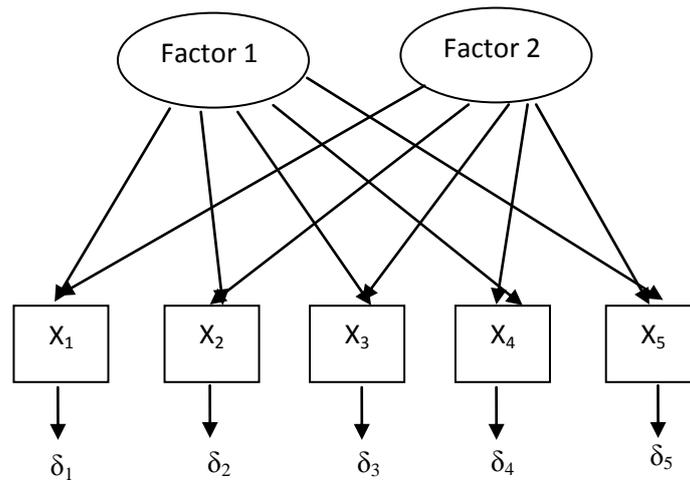


Figura 1 Análisis Factorial Exploratorio

– *Análisis Factorial Confirmatorio (CFA)*

Esta técnica analiza las medidas a priori del modelo, en donde el número de factores y su correspondencia a los indicadores son especificados explícitamente (Kline 2005, 71). Es decir, con base en consideraciones teóricas se establece que algunas variables son indicadoras de determinados factores. Esto da pauta a especificar la estructura del modelo con el objetivo de confirmarla. La Figura 1-3 muestra el diagrama del Análisis Factorial Confirmatorio.

El modelo general para el análisis factorial confirmatorio se indica con la siguiente ecuación:

$$X = \Lambda_x \xi + \delta$$

X = vector de $q \times 1$ de variables observadas

Λ_x = matriz de $q \times n$ de coeficientes

ξ = vector de $n \times 1$ de variables latentes

δ = vector de $q \times 1$ de errores

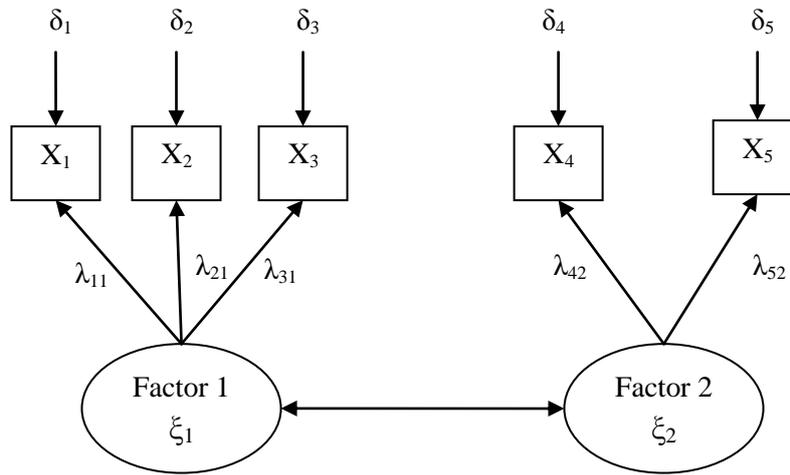


Figura 2 Análisis Factorial Confirmatorio

Desarrollando la ecuación

$$X_i = \lambda_{i1}\xi_1 + \delta_i \quad \text{para } i = 1,2,3$$

$$X_j = \lambda_{i2}\xi_2 + \delta_j \quad \text{para } j = 4,5$$

$$\begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \end{bmatrix} = \begin{bmatrix} \lambda_{11} & 0 \\ \lambda_{21} & 0 \\ \lambda_{31} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \end{bmatrix} \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix} + \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \end{bmatrix}$$

Para este modelo se asumen algunos supuestos:

- Los errores aleatorios no están correlacionados con las variables latentes, es decir

$$E(\xi\delta') = 0.$$

- Debido a que se sugiere que las variables se estandaricen, entonces $E(X_i) = 0$

- También se supone que $E(\delta_i) = 0$

Es posible suponer que los errores están correlacionados entre ellos. Las variables latentes si están correlacionadas entre ellas, tal como se indica en la Figura 1-3. Los coeficientes que

conforman la matriz Λ_x , indican la relación de las variables latentes con las variables observadas.

El investigador deberá considerar incluir el mayor número posible de indicadores para cada variable latente, siempre que esto no genere problemas en la estimación. El trabajo de Marsh, HAU, Balla and GRayson (1998) dan indicadores de que se obtienen pocas soluciones impropias y resultados más estables dando un mayor número de indicadores por variable latente (Haenlein 2004, 293). Acerca de este mismo punto Kline (2005, 111) sugiere, en el enfoque basado en covarianzas, al menos tres indicadores por factor, especialmente si el tamaño de la muestra es pequeño.

1.3.4 Modelo de Ecuaciones Estructurales (SEM)

El SEM engloba características del Análisis de Sendero y del Análisis Factorial. De manera que algunas de las limitaciones de los modelos mencionados, son superadas en el modelo estructural.

El SEM incluye metodologías estadísticas utilizadas para estimar cadenas de relaciones causales, definidas en modelos teóricos, relacionando dos o más variables latentes, cada una medida a través de una número de variables manifiestas o indicadores (Esposito *et al.* 2010, 47).

El “SEM puede ser (y a menudo es) usado para probar (y consecuentemente soportar o rechazar) supuestos teóricos con datos empíricos” (Haenlein 2004, 286). Esta característica, como se ha venido mencionando a lo largo de este trabajo, indica las relaciones causales a probar, en caso de considerar modificaciones, deben ser soportadas por los supuestos teóricos.

El SEM está compuesto por dos “sub-modelos” o partes, uno establecen asociación entre las variables latentes, el cual también es nombrado en la literatura como modelo de medida o *outer model*. El otro modelo muestra la asociación entre variables latentes y manifiestas, y es conocido como modelo estructural o *inner model*. Los términos *outer* e *inner*, son utilizados en trabajos enfocados en Mínimos Cuadrados Parciales (PLS por sus siglas en inglés⁵). En adelante se observará que el modelo de medida funciona como el análisis factorial y el modelo estructural como análisis de senderos, ambos descritos anteriormente.

A diferencia del Análisis de Senderos, SEM permite la inclusión de variables latentes, puesto que incorpora un modelo de medida en donde las variables observables son los indicadores de la variable latente o constructo.

En SEM, no hay correlación entre las variables latentes como en Análisis Factorial, sin embargo sí hay una asociación causal entre las variables latentes. Otra característica importante es que algunas de las variables latentes se describen en términos de otras, de manera que algunas variables latentes tienen el papel de dependientes y posteriormente toman el rol de variables independientes. Por lo que se refiere a los errores, en SEM las variables latentes tienen asociado un disturbio, el cual refleja la parte omitida en el constructo.

En el SEM representado en la Figura 1-6, las variables latentes asocian a dos o más variables observables, lo cual es considerado como un modelo de medida multi-indicador. También es posible tener un indicador por variable latente, lo cual no es recomendable, esta situación será descrita al abordar los modelos de ecuaciones estructurales estimados con PLS.

⁵ Mínimos Cuadrados Parciales en adelante PLS

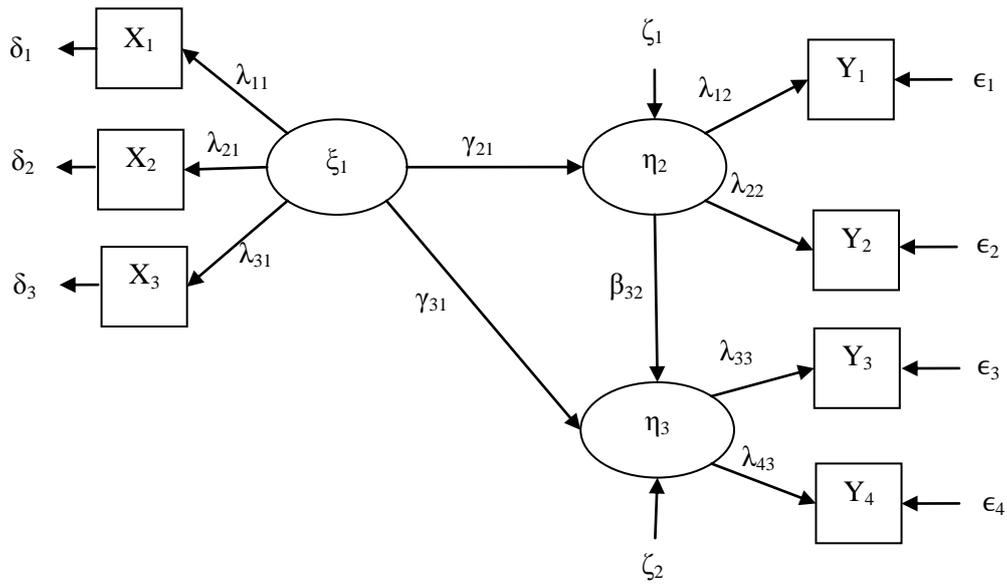


Figura 1-6 Modelo de Ecuaciones Estructurales

Tal como se mostró en las secciones correspondientes a Análisis de Senderos y Análisis Factorial, las relaciones entre las variables tienen una representación matemática. La parte estructural del los modelos se denota por:

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

Donde

ξ = vector de $n \times 1$ de variables latentes independientes

η = vector de $m \times 1$ de variables latentes dependientes

β = matriz de $m \times m$ de coeficientes correspondientes a η

Γ = matriz de $m \times n$ de coeficientes de ξ a η

ζ = vector de $m \times 1$ de errores asociado a η

Se establecen los supuestos de $E(\zeta') = 0$ y que $E(\xi\xi') = 0$ por no estar correlacionadas los errores con las variables.

Para el modelo de medida la ecuación es:

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

Y = vector de $q \times 1$ de variables observadas

Λ_y = matriz de $q \times n$ de coeficientes

η = vector de $n \times 1$ de variables latentes

ϵ = vector de $q \times 1$ de errores de medida

El planteamiento del modelo estructural, presentado en la Figura 1-6, con matrices es:

$$\begin{bmatrix} \eta_2 \\ \eta_3 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ \beta_{32} & 0 \end{bmatrix} \begin{bmatrix} \eta_2 \\ \eta_3 \end{bmatrix} + \begin{bmatrix} \gamma_{21} \\ \gamma_{31} \end{bmatrix} (\xi_1) + \begin{bmatrix} \zeta_1 \\ \zeta_2 \end{bmatrix}$$

y para el modelo de medida es:

$$\begin{bmatrix} X_1 \\ X_2 \\ X_3 \end{bmatrix} = \begin{bmatrix} \lambda_{11} \\ \lambda_{21} \\ \lambda_{31} \end{bmatrix} [\xi_1] + \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \end{bmatrix}$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{bmatrix} = \begin{bmatrix} \lambda_{12} & 0 \\ \lambda_{22} & 0 \\ 0 & \lambda_{33} \\ 0 & \lambda_{43} \end{bmatrix} \begin{bmatrix} \eta_2 \\ \eta_3 \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \end{bmatrix}$$

Cuando el resultado de la estimación es inadmisibles, es decir, hay parámetros estimados con valores ilógicos, tal como varianzas negativa, o correlaciones entre un factor y un indicador con valor absoluto mayor a 1, puede ser causado por: a) errores en la especificación del modelo, b) no identificación del modelo, c) presencia de valores atípicos o una combinación de tamaño de muestra pequeño y sólo dos indicadores por factor en un modelo de medida, d) valores de inicio inadecuados o correlaciones extremadamente altas o bajas que resultan en empíricas sobre identificaciones (Chen *et al.* 2001 citado en Kline 2005, 115).

Aplicaciones del Modelo de Ecuaciones Estructurales, para la evaluación de la satisfacción son mostradas en el siguiente Capítulo 4.

1.4 Conclusiones

La medición de la satisfacción requiere herramientas que consideren la inclusión de variables latentes y la interacción entre ellas. Las variables manifiestas, a su vez se valen de indicadores o variables observadas para su evaluación. Las herramientas de análisis multivariando, satisfacen alguno de estos requerimientos.

Los Modelos de Ecuaciones Estructurales retoman elementos de técnicas como Análisis de Senderos, Análisis Factorial así como Regresión Múltiple. Algunos de estas técnicas se han revisado brevemente en este capítulo, buscando evidenciar que la parte estructural del Modelo de Ecuaciones Estructurales opera como el Análisis de Senderos en donde se calculan las relaciones causales entre variables observables y por lo que se refiere al modelo de medida, la técnica que genera índices a partir de las combinaciones lineales de las variables observadas en cuestión, es el Análisis Factorial.

La composición del Modelo de Ecuaciones Estructurales por un modelo de medida y un modelo estructural lo hace más robusto que las técnicas de Análisis Factorial y Análisis de Senderos aplicadas por separado.

La característica más subrayada en la literatura, para el uso de esta herramienta, es la identificación del modelo. Como se indicó, éste consiste en la inclusión o no de relaciones entre las variables así como la direccionalidad causal, punto que debe ser abordado por el investigador. En este mismo sentido hay que resaltar que para que un modelo pueda indicar causalidad, es necesario reunir varias características; indicadores aceptables del modelo, aceptación teórica del modelo, eliminación de modelos equivalentes y replicación con muestras independientes.

2. Capítulo

Marco de Referencia. Índices de Satisfacción

2.1 Introducción

El objetivo de este capítulo es mostrar los SEM utilizados en la evaluación de la *satisfacción*, en índices internacionales. Anteriormente se mencionó como una característica fundamental para el diseño de SEM, el conocimiento teórico del fenómeno a estudiar. La base teórica determina las variables implicadas en el modelo, los indicadores de medición para cada variable, así como las relaciones causales. Es por tanto de gran interés revisar los modelos utilizados para la medición de la satisfacción con esta metodología.

Una vez que se han presentado, en el Capítulo 1, los elementos clave para la comprensión de los SEM, se pretende que la exposición de este Capítulo sea clara y que se identifique la evaluación de la satisfacción como una aplicación de SEM.

A lo largo de este capítulo se mostrarán algunos índices internacionales de satisfacción, sus características y modelos asociados. Al finalizar la descripción de los índices, podremos observar que todos parten de la misma base. La identificación de similitudes y diferencias contribuirá a analizar el desempeño del modelo propuesto para el Índice Mexicano de Satisfacción de Usuarios (IMSU)⁶.

Un último elemento que destaca en este capítulo es la exposición de evaluaciones de satisfacción para programas sociales, con la metodología abordada, que se han realizado en México.

⁶ Índice Mexicano de Satisfacción de Usuarios de aquí en adelante IMSU

2.2 Índices Nacionales de Satisfacción

En las últimas décadas la medición de la satisfacción ha cobrado tal relevancia, que algunos países y continentes han desarrollado índices para dicho fin. Los índices nacionales revisados en adelante, miden la satisfacción de consumidores de productos, servicios de empresas privadas y servicios gubernamentales, tal es el caso del American Customer Satisfaction Index (ACSI)⁷.

La implementación de índices nacionales de satisfacción, ha permitido a las naciones realizar comparativos entre diferentes empresas, periodos de tiempo y segmentos de consumidores.

Basados en los gurúes de la calidad, el cliente, consumidor o usuario, es el elemento central para el diseño y mejora de un producto o servicio. De manera que la medición de la satisfacción no debería soslayarse, sobre todo ante la competencia globalizada que ha dado a los consumidores el poder de decisión. Si el consumidor no está satisfecho con el producto o servicio adquirido es muy probable que no lo vuelva a comprar y que no lo recomiende. Esta situación no opera de la misma manera para los usuarios de servicios gubernamentales, quienes no tienen otra opción que realizar trámites para solicitar el servicio que se ofrece. Ante la insatisfacción, los usuarios de servicios gubernamentales pierden confianza en su gobierno.

El desarrollo de esta tesis se centra en la evaluación de la satisfacción de los beneficiarios de programas sociales. En este sentido la evaluación de la satisfacción busca ser la voz de los usuarios. Este elemento es de suma importancia para los tomadores de decisiones y diseñadores de programas sociales interesados en utilizar eficientemente los recursos.

⁷ American Customer Satisfaction Index, en adelante ACSI

Cortázar, en el libro auspiciado por el Banco Interamericano de Desarrollo (BID), enuncia lineamientos y recomendaciones para el diseño, implantación y evaluación de Programas Sociales, en donde subraya la importancia de incluir la voz del usuario, así como evaluar la satisfacción, para lograr la calidad durante la implementación de los programas sociales. La primera estrategia considera el voluntariado de los usuarios, sin que tengan influencia en las decisiones y administración del servicio. La segunda estrategia enfoca la orientación hacia el usuario, al considerar sus expectativas y satisfacción. Los operadores administran y la información es utilizada para mejorar. La tercera estrategia reconoce a los usuarios como actores en toma de decisiones, con responsabilidad en implementación y evaluación (Cortázar 2007, 5-7).

Considerar la satisfacción medida a partir de un sólo indicador, puede dejar de lado elementos que contribuyen a su explicación, por lo tanto es deseable utilizar varios indicadores en busca de una medida más confiable.

La estimación de impactos significativos sobre la satisfacción de los beneficiarios de programas sociales, a través del análisis de SEM, tiene ventajas sustanciales sobre los estudios descriptivos de satisfacción a los que estamos acostumbrados. Es posible identificar áreas de mejora, a partir de las estimaciones de los impactos.

Los índices desarrollados para medir la satisfacción se basan, en general, en el Desconfirmación (Disconfirmation paradigm), el cual establece la relación entre la satisfacción y las expectativas iniciales. Las expectativas pueden: 1) confirmarse si el producto se desempeña como se espera; 2) desconfirmarse de forma negativa, cuando el producto se

desempeña pobremente en comparación con las expectativas; 3) des confirmarse de forma positiva, cuando son superadas las expectativas (Huerta 2011, 41).

La metodología de los índices de satisfacción, a la que se hace referencia en este trabajo, es aquella relacionada con SEM, metodología detallada en el Capítulo 3 de este documento. Se abordarán los siguientes índices de satisfacción: Barómetro Sueco de Satisfacción del Consumidor (SCSB), American Customer Satisfaction Index (ACSI), European Customer Satisfaction Index (ECSI) y el modelo de Hong Kong, Índice de Satisfacción del Consumidor en Hong Kong (HKCSI).

Algunas consideraciones en la construcción de una medida de la satisfacción del consumidor son: 1) la satisfacción general o global con el producto es consistente con la medición acumulada de satisfacción; 2) el modelo tiene que incluir una medida de confirmación de expectativas; 3) el modelo tiene que incluir una comparación entre el rendimiento del producto y el concepto ideal del consumidor del rendimiento. Los tres indicadores de satisfacción son: la satisfacción global, la confirmación de expectativas y comparación con el producto ideal (Lai K. Chan *et al.* 2003, 876)

Para la construcción de este capítulo me baso en la elaboración del marco teórico del Índice Mexicano de Satisfacción de Usuarios de Programas Sociales Mexicanos (IMSU-PSM)⁸, desarrollada por el Dr. Frederick Golden, en proceso de publicación.

Comenzaremos por describir el Barómetro Sueco de Satisfacción de Consumidor, por ser el primero que se creó y ser la base de otros índices.

⁸ Índice Mexicano de Satisfacción de Usuarios de Programas Sociales Mexicanos, en adelante IMSU-PSM

2.1.1 Barómetro Sueco (SCBS)

El Barómetro Sueco, de acuerdo con NERA (National Economic Research 1991), establecido en 1989, utilizó el modelo econométrico diseñado por Claes Fornell y sus colegas la Universidad de Michigan. Se reconoce como 1) un gran esfuerzo, para medir productos y servicios de calidad; 2) factibilidad de usar el método de encuesta para evaluar la calidad en una amplia escala y 3) relación de medidas de calidad con la conducta de los consumidores (The ACSI technical staff 2005, 2).

El diagrama de trayectorias de este índice se aprecia en el Figura 2-1. El modelo muestra que las causas directas de la satisfacción (índice global) son las expectativas y la percepción del desempeño. Expectativa es la única variable exógena del modelo, y se relaciona directamente con la percepción y con la satisfacción. Del lado derecho se tiene como efectos directos de la satisfacción; quejas y lealtad. Finalmente la variable quejas impacta directamente la lealtad.

La variable exógena del modelo es expectativas (ξ) y las variables endógenas (η_i) son percepción, satisfacción, quejas y lealtad. Las relaciones entre variables latentes, se indica con la letra griega β , de manera que β_{42} es el coeficiente de relación entre “satisfacción” (η_2) y “lealtad” (η_4). Las relaciones entre variables latentes exógenas y variables latentes endógenas, esta denotado por la letra γ , el coeficiente de relación γ_{21} muestra el impacto “expectativas” (ξ) y “satisfacción” (η_2).

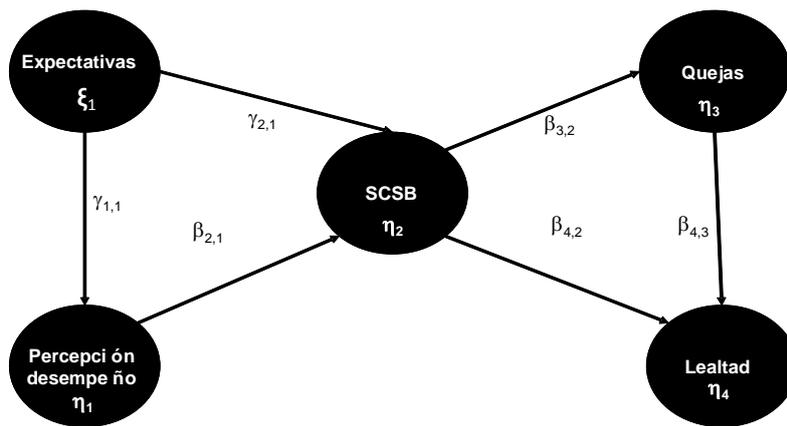


Figura 3 Barómetro Sueco: Diagrama de trayectorias

Los indicadores de las variables latentes se denotan con y cuando son determinados por la variable exógena y x cuando la variable causal es endógena. Los coeficientes de relación entre las variables latentes y sus indicadores (variables manifiestas), se denota con la letra λ , tal como λ_{32} muestra la relación entre y_3 y η_2 . En el caso de las expectativas, sólo hay un factor manifiesto denotado por x .

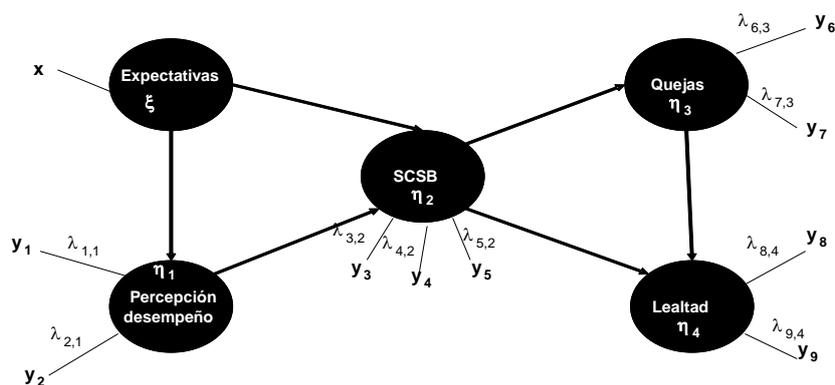


Figura 4 Barómetro Sueco: Relaciones entre factores manifiestos y latentes

Las variables manifiestas que conforman la parte medible del modelo se presentan en la siguiente tabla.

Reactivo	Variable manifiesta	Variable Latente
y_1	Calidad dado el precio	Percepción desempeño
y_2	Precio dada la calidad	Percepción desempeño
y_3	Satisfacción en lo general	Satisfacción
y_4	Confirmación de las expectativas	Satisfacción
y_5	Distancia del servicio producto ideal	Satisfacción
y_6	Quejas del personal	Quejas
y_7	Quejas de la gerencia	Quejas
y_8	Tolerancia al incremento de precios	Lealtad
y_9	Intención de recompra	Lealtad
x	Expectativas	Expectativas

Tabla 2-1 Barómetro Sueco. Variables Manifiestas

2.1.2 American Customer Satisfaction Index (ACSI)

La metodología ACSI, establecida en 1994, está basada en el Barómetro Sueco de Satisfacción del Consumidor. ACSI fue creado originalmente para tener un termómetro de la economía norteamericana. Se fundamenta en la premisa de que un consumidor satisfecho es el reflejo de una economía sana (The ACSI technical staff 2005, 2).

La metodología ACSI, es actualmente utilizada para producir índices nacionales de satisfacción en Gran Bretaña y República Dominicana. Versiones de ACSI se han aplicado en Colombia, México, Singapur, Corea del Sur, Suecia y Turquía. Estudios piloto se realizan en

2010 en República Dominicana, Barbado y Sudáfrica. (www.theacsi.org consultada 19 octubre 2010)

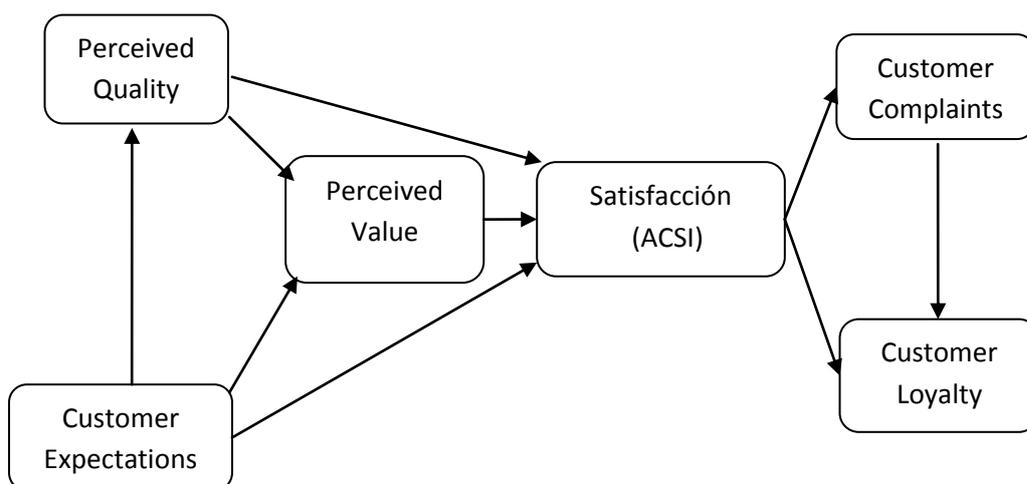
Los elementos referidos sobre ACSI, están tomados de *American Customer Satisfaction Index (ACSI) Methodology Report, 2005*.

“ACSI mide 10 sectores del North American Industry Classification System (NAICS), que producen productos y venta de servicios directamente al consumo de los hogares. Estos sectores son: 1) servicios, 2) manufactura/bienes no durables, 3) manufactura/bienes durables 4) comercio al por menor, 5) transportación y almacenamiento, 6) información, 7) finanzas y de seguros, 8) cuidado de la salud y asistencia social, 9) alojamiento y comida rápida, y 10) administración pública” (The ACSI technical staff 2005, 3).

En 1999, el gobierno federal seleccionó a ACSI para ser una medida estándar para la evaluación de la satisfacción de los ciudadanos, ACSI mide sobre 200 servicios de gobierno federal y local.

Para su evaluación, ACSI utiliza datos provenientes de encuestas telefónicas (asistidas por computadora) aplicadas a clientes seleccionados aleatoriamente. El entrevistado debe calificar como comprador de un producto específico (o servicio) en un periodo determinado.

El diagrama de trayectorias del ACSI para sector privado se observa en la Figura 2-3.

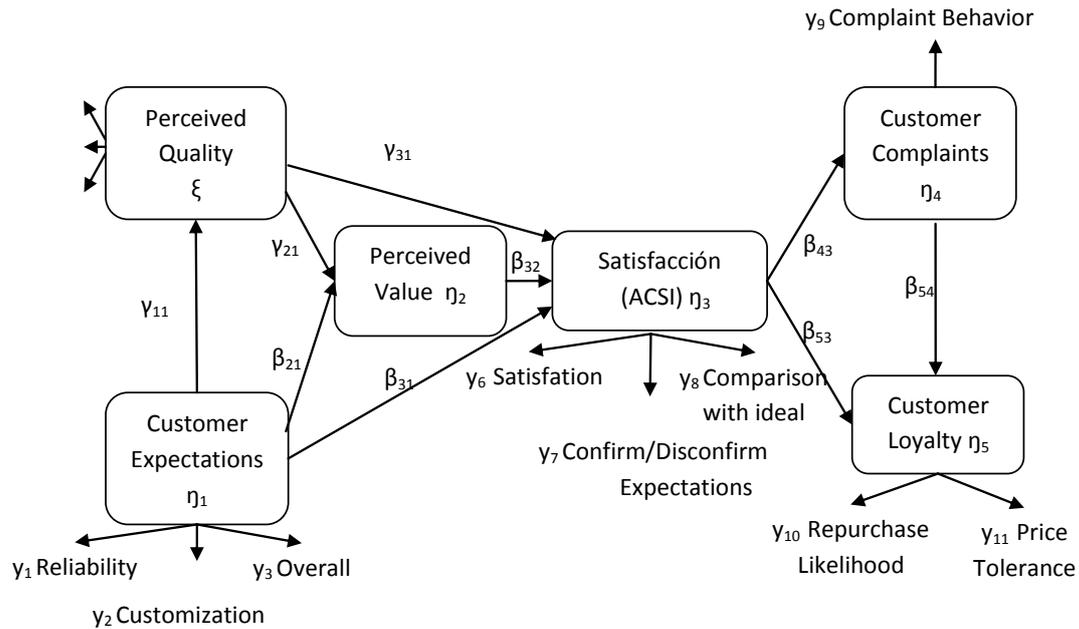


Fuente: The ACSI technical staff 2005, 9

Figura 5 ACSI sector privado: Diagrama de trayectorias

El índice de satisfacción es causado directamente por las expectativas, la calidad percibida y valor percibido. Como resultados de la satisfacción se encuentran las quejas y la lealtad. Se puede observar el establecimiento de relaciones directas e indirectas entre estas variables, tal es el caso de la variable exógena expectativas, que explica a la calidad percibida y ésta a su vez contribuye indirectamente a explicar la satisfacción a través del valor percibido.

En la Figura 2-4 se observan las variables manifiestas (indicadores) y sus relaciones con las variables latentes. La lectura de este diagrama es similar al presentado en el punto anterior.



Fuente: The ACSI technical staff 2005, 9

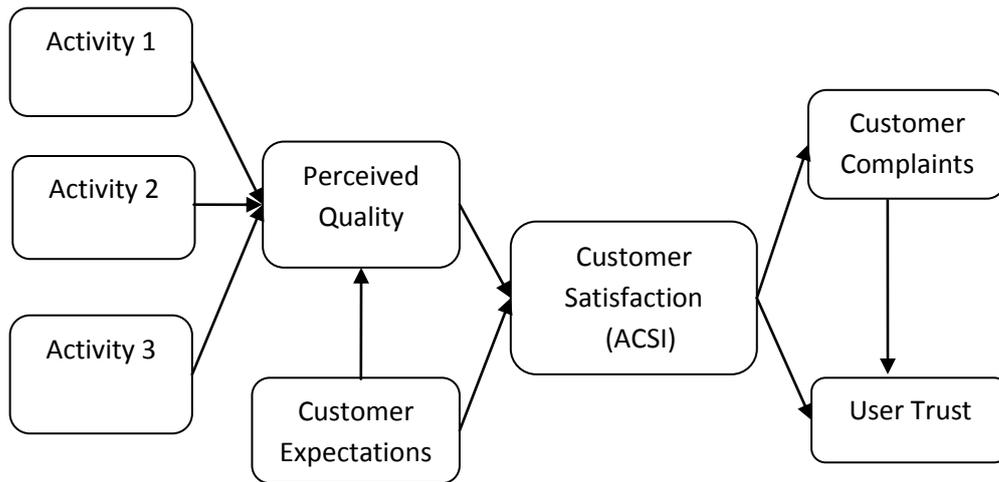
Figura 6 ACSI sector privado: Variables manifiestas y su relación con las latentes

El diagrama de trayectorias utilizado para la evaluación de la satisfacción de servicios gubernamentales, considera modificaciones al diagrama presentado en la Fig. 2-3. Dichos cambios consisten en:

- 1) Eliminar la variable latente “valor percibido” que tiene que ver con el precio del producto o servicio. En el caso de servicios gubernamentales esa dimensión carece de sentido.
- 2) Sustitución de la variable “lealtad” por “confianza”. Debido a que los usuarios de servicios gubernamentales no tienen opciones para realizar trámites, o solicitar servicios en otra institución, no se puede hablar de lealtad o de la propensión a

volver a comprar en una organización. Por el contrario el término “confianza” se adapta más a esta situación.

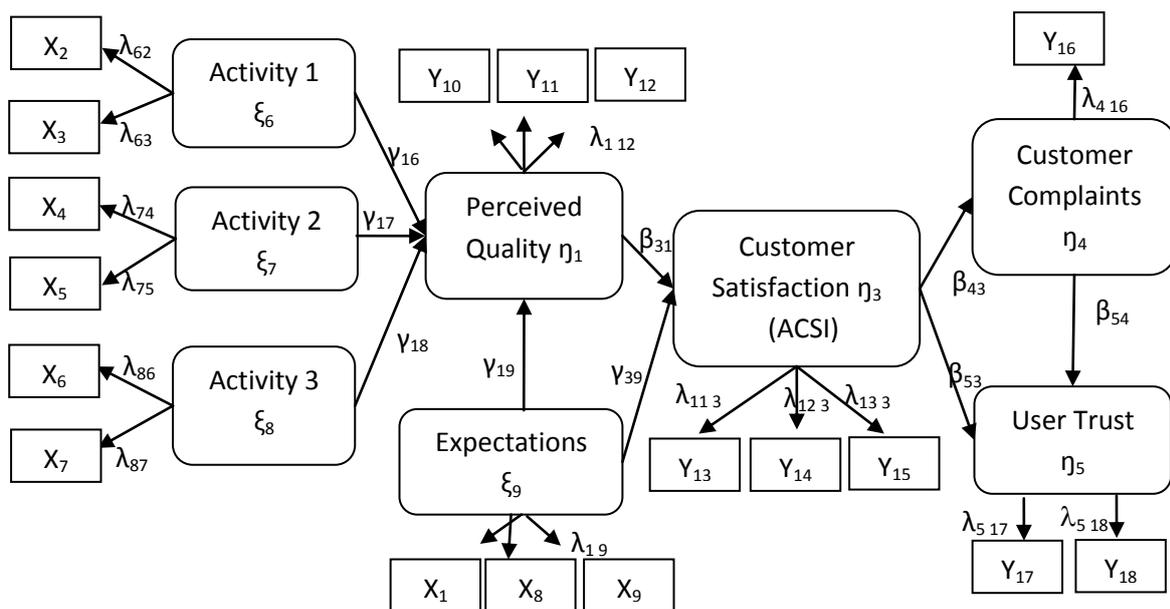
El diagrama de trayectorias resultante para el sector público, se muestra en la Figura 5.



Fuente: The ACSI technical staff 2005, 11

Figura 7 ACSI: Diagrama de trayectorias para el caso de sector público

Las variables manifiestas y los coeficientes de regresión se muestran en el diagrama de trayectorias de la Figura 2-6.



Fuente: The ACSI technical staff 2005, 11

Figura 8 ACSI sector público: Coeficientes de regresión

Los indicadores que integran el modelo de medida, y que aparecen como reactivos en la encuesta aplicada, se muestran en la siguiente tabla.

Indicador	Variable manifiesta	Variable latente
X_1	Expectativa general de calidad del servicio antes de uso	Expectativas del usuario
X_2	Indicador de actividad 1	Actividad 1: Un factor causante de calidad percibida
X_3	Indicador de actividad 1	Actividad 1: Un factor causante de calidad percibida
X_4	Indicador de actividad 2	Actividad 2: Un factor causante de calidad percibida
X_5	Indicador de actividad 2	Actividad 2: Un factor causante de

		calidad percibida
X_6	Indicador de actividad 3	Actividad 3: Un factor causante de calidad percibida
X_7	Indicador de actividad 3	Actividad 3: Un factor causante de calidad percibida
Y_{10}	Evaluación general de calidad del servicio después de uso	Calidad percibida
Y_{11}	Evaluación general de satisfacción	Satisfacción del usuario
Y_{12}	Grado en que la calidad excede o no llega al nivel esperado	Satisfacción del usuario
Y_{13}	Comparación de la calidad real con la calidad ideal del servicio	Satisfacción del usuario
Y_{14}	Si el usuario ha registrado quejas formales	Quejas del usuario
Y_{15}	Disposición de recomendar a otros el servicio	Confianza
Y_{16}	Confianza en la capacidad de la agencia de ofrecer consistentemente servicio de alta calidad	Confianza

Tabla 2-2 ACSI. Variables Manifiestas

2.1.3 European Customer Satisfaction Index (ECSI)

El modelo “ECSI fue desarrollado en 1999 y tiene como objetivo proveer, a las empresas, servicios públicos, inversionistas y entidades reguladoras, de un índice que les permita conocer y evaluar el grado de satisfacción que experimentan sus consumidores. El modelo ECSI es esencialmente similar al modelo ACSI. La única variable latente distinta al modelo ACSI es la variable imagen. Esta variable es un antecedente opcional que se relaciona con la marca y con las asociaciones que los consumidores tienen en relación al producto, marca o

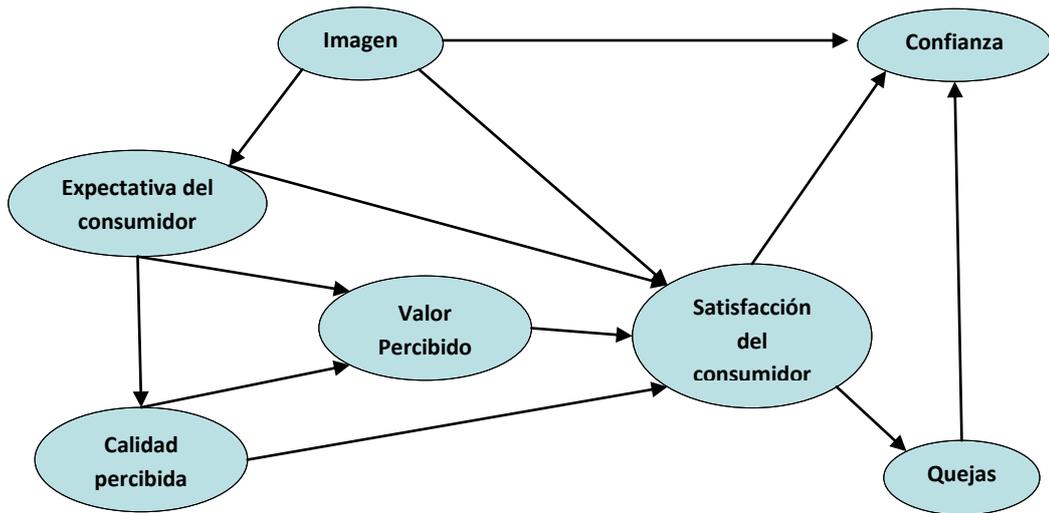
empresa. De acuerdo con el modelo ECSI, la variable imagen está positivamente relacionada con calidad, satisfacción y con la lealtad” (Marshall *et al.* 2003, 56).

Johnson y Martesen (2001; 2000 citados en Hsu S-H *et al.* 2006, 356) resaltan que los investigadores han encontrado que las expectativas tienen bajo impacto en los modelos de Satisfacción, de manera que sugieren reemplazarla por la variable imagen.

El modelo ECSI es aplicable a diferentes industrias. Está basado en teorías y enfoques de la conducta de los consumidores bien establecidos. ECSI es una adaptación del barómetro Sueco y es compatible con el ACSI (Tenenhaus *et al.* 2005, 161).

El diagrama de trayectorias de este índice se muestra en la Figura 2-7, está tomado del estudio publicado en Tenenhaus (2005, 161).

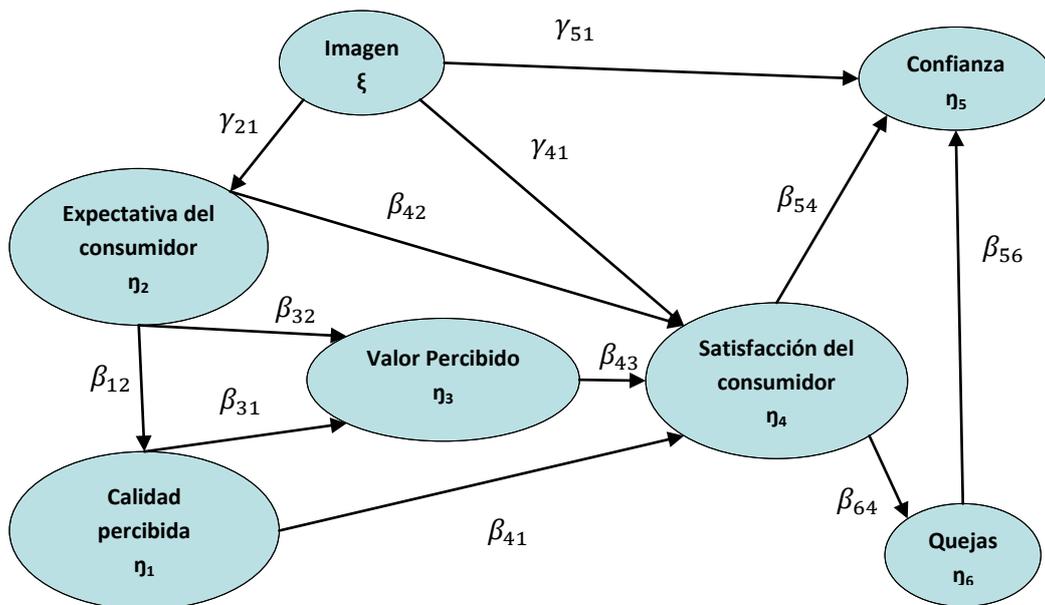
Resalta de este índice la inclusión de la variable latente imagen y su relación directa con las variables expectativas, satisfacción y lealtad. Las relaciones entre las variables latentes, en este diagrama se incrementan, con respecto al modelo de ACSI mostrado anteriormente. Existen diagramas tanto de ACSI (The ACSI technical staff 2005, 10) como de ECSI (Casas 2002, 7) en donde se incluye la variable referente a la calidad del servicio o bien. Hay modelos en donde la variable de calidad del servicio no está incluida, sin embargo sus indicadores son incluidos como indicadores de otra variable.



Fuente: Tenenhaus et al. 2003, 161

Figura 9 ECSI: Diagrama de trayectorias

En la Figura 8 se observan las relaciones entre los factores latentes. Por simplicidad se omitieron de la figura los factores manifiestos que se enlistan en la Tabla 2-3. El diagrama y la tabla son tomados de Tenenhaus. (2003, 7-8).



Fuente: Tenenhaus et al. 2003, 161

Figura 10 ECSI: Variables latentes y sus relaciones

Indicador	Variable manifiesta	Variable latente
X_1	Se puede confiar en lo que dice y hace	Imagen
X_2	Es estable y firmemente establecido	Imagen
X_3	Tiene una contribución social a la sociedad	Imagen
X_4	Se ocupa de los clientes	Imagen
X_5	Es innovador y con visión del futuro	Imagen
Y_1	Expectativas de la calidad global en el momento en que llegó a ser consumidor del proveedor	Expectativas
Y_2	Expectativas para proporcionar productos y servicios para satisfacer sus necesidades personales	Expectativas
Y_3	Frecuencia con la que se espera que las cosas podrías ir mal	Expectativas
Y_4	Calidad general percibida	Calidad del producto
Y_5	Calidad de los servicios que usa	Calidad del producto
Y_6	Calidad percibida en cuanto a la gama de servicios	Calidad del producto
Y_7	Calidad percibida en cuanto a calidad técnica	Calidad del producto
Y_8	Calidad percibida en cuanto a atención personal	Calidad del servicio
Y_9	Confiabilidad y exactitud de los productos y servicios prestados	Calidad del producto
Y_{10}	Calidad y transparencia de la información dada	Calidad del producto
Y_{11}	Valor percibido en cuanto a la relación productos y servicios – precio	Valor percibido
Y_{12}	Valor percibido en cuanto a la relación precio – productos y servicios	Valor percibido
Y_{13}	Satisfacción global	Satisfacción
Y_{14}	Cumplimiento de expectativas	Satisfacción
Y_{15}	Diferencia respecto del ideal	Satisfacción
Y_{16}	Queja en el último año. Que tal bien o mal fue atendida su última queja	Quejas

	O No tuvo queja el último año. Imagine que hubiera tenido que quejarse por mala calidad del servicio o producto. En qué medida cree usted que su proveedor se preocupa por su queja	
Y ₁₇	Lealtad del cliente en cuanto a la repetición de la compra/utilización del servicio	Lealtad
Y ₁₈	Sensibilidad al precio	Lealtad
Y ₁₉	Recomendación	Lealtad

Tabla 2-3 ECSI. Variables Manifiestas

2.1.4 Índice de Satisfacción del Consumidor en Hong Kong (HKCSI)

La estructura de este índice es muy similar a las de los índices mostrados anteriormente, sin embargo se observan diferencias sustanciales en el modelo, en la estimación y en la formación del indicador nacional.

Se seleccionan 60 productos en el IPC (Índice de Precios al Consumidor) que en conjunto representan 80 por ciento de los gastos de los consumidores. Para cada producto se hacen aproximadamente 180 entrevistas telefónicas. Se calcula un índice de cada producto y se agregan los índices utilizando el porcentaje que el producto representa en el IPC. (Lai K. Chan *et al.* 2003, 882-883)

Lai K. Chan (2003) reporta el resultado de 10000 entrevistas telefónicas en los años 1998-2000 sobre 60 productos (bienes y servicios). Las características del HKCSI son:

- 1) Se consideran, directamente en el modelo, características del encuestado, como: edad, nivel de educación, nivel de ingresos
- 2) Se evalúan categorías de productos y servicios en lugar de empresas. No hay intento de distinguir entre productos individuales o de distintas marcas dentro de una categoría
- 3) Para el índice global se utiliza una ponderación basada en el IPC no el peso del producto o servicio en el PIB (Producto Interno Bruto).

La concentración en productos, y no empresas, se debe a que la economía de Hong Kong está fuertemente orientada hacia servicios en lugar de manufactura, lo que implica que muchos bienes son importados (Lai K. Chan *et al.* 2003, 874).

Un beneficio del índice es que indica la calidad del ambiente de negocios en Hong Kong y por tanto la potencial atracción de Hong Kong para establecer negocios (Lai K. Chan *et al.* 2003, 903).

En la figura 9 se muestra el diagrama de trayectorias del modelo HKCSI.

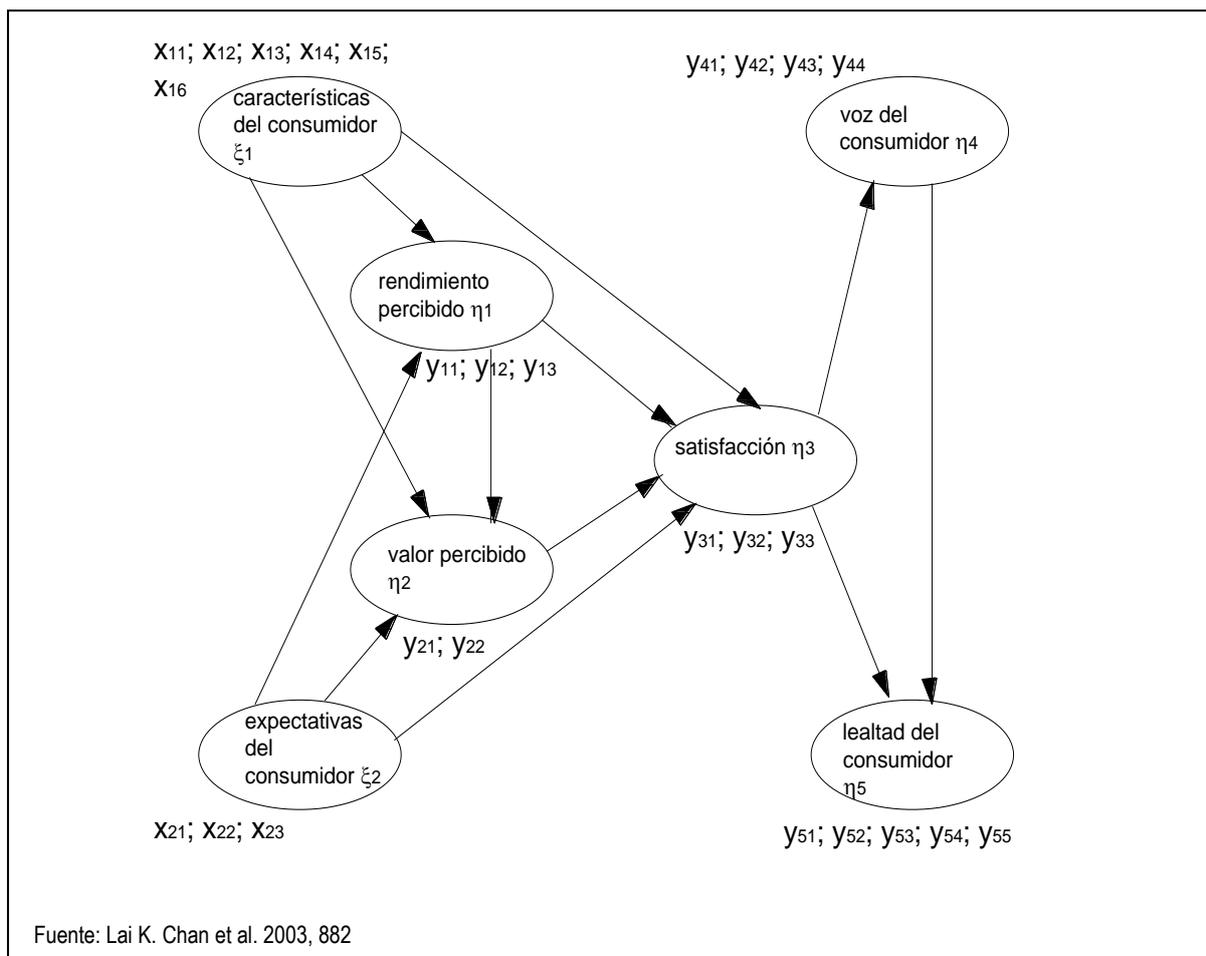


Figura 11 Modelo HKCSI: Diagrama de trayectoria

La satisfacción del consumidor con un producto es la respuesta a una evaluación de la discrepancia percibida entre una expectativa de su rendimiento y la percepción de su rendimiento. La evaluación de satisfacción puede estar basada en una sola transacción o basada en la experiencia acumulada de varias transacciones. El HKCSI como la mayoría de índices evalúa la satisfacción acumulada (Lai K. Chan *et al.* 2003, 874-875).

En el diagrama se puede observar que la satisfacción está determinada directamente por las variables latentes: rendimiento, valor percibido, características del consumidor y expectativas. Se muestran las relaciones directas e indirectas entre estas variables latentes,

que a su vez están medidas con indicadores propios. Las consecuencias de la satisfacción en el modelo son: 1) la tendencia de cambiar a otras marcas o alternativas cuando el cliente no está satisfecho y 2) la tendencia de expresar opiniones negativas cuando no está satisfecho. Se incorporan estas variables latentes consecuentes de satisfacción en ‘voz del consumidor’ y en ‘lealtad del consumidor’, respectivamente (Lai K. Chan *et al.* 2003, 879). Las dos variables latentes exógenas son: 1) expectativas del consumidor, 2) características del consumidor.

Este modelo es único en la inclusión de características del consumidor como variables latentes explícitas en el modelo. El modelo de medida para esta variable se plantea como formativo, no como reflexivo (la descripción de este punto se hace en el Capítulo 3). Los indicadores de la variable son: género, edad, educación, ingresos personales, ingresos de la familia y tamaño de la familia. Se cree que esta variable caracteriza directamente el impacto de diferencias entre clientes sobre satisfacción (Lai K. Chan *et al.* 2003, 880-881).

La estimación del modelo se hace con el método de Mínimos Cuadrados, por las bondades del método. Para los valores perdidos, se utiliza el algoritmo de máxima expectativa (Lai K. Chan *et al.* 2003, 886-887).

El conjunto de ecuaciones formuladas en el modelo son: las ecuaciones de indicadores reflexivos, las ecuaciones de indicadores formativos, las ecuaciones estructurales latentes, las relaciones de ponderación, la ecuación para calcular el índice.

Los indicadores de las variables latentes para el modelo de Hong Kong se muestran en la Tabla 2-4. Los indicadores en letra itálica son referencias para la dirección positiva de cambios de la variable latente asociada.

Indicador	Variable manifiesta	Variable latente
X ₁₁	Género	Características del consumidor
X ₁₂	Preparación académica	Características del consumidor
X ₁₃	Edad	Características del consumidor
X ₁₄	<i>Ingreso personal</i>	Características del consumidor
X ₁₅	Ingreso familiar	Características del consumidor
X ₁₆	Tamaño familiar	Características del consumidor
X ₂₁	<i>Expectativas globales</i>	Expectativas globales
X ₂₂	Ajuste al uso esperado	Expectativas globales
X ₂₃	Confiabilidad	Expectativas globales
Y ₁₁	<i>Rendimiento global</i>	Rendimiento percibido
Y ₁₂	Ajuste al uso esperado	Rendimiento percibido
Y ₁₃	Confiabilidad	Rendimiento percibido
Y ₂₁	<i>Precio por calidad recibida</i>	Valor percibido
Y ₂₂	Calidad por precio pagado	Valor percibido
Y ₃₁	<i>Satisfacción global</i>	Satisfacción
Y ₃₂	Confirmación de expectativas	Satisfacción
Y ₃₃	Comparación con ideal	Satisfacción
Y ₄₁	<i>Quejas expresadas a conocidos</i>	Voz del consumidor
Y ₄₂	Valoración expresada a conocidos	Voz del consumidor
Y ₄₃	Quejas expresadas al público	Voz del consumidor
Y ₄₄	Valoración expresada al público	Voz del consumidor
Y ₅₁	Intención de adquirir más del mismo producto	Lealtad del consumidor
Y ₅₂	<i>Intención de adquirir cuando se reemplaza</i>	Lealtad del consumidor

Y ₅₃	Tolerancia para aumento de precio	Lealtad del consumidor
Y ₅₄	Tolerancia respecto a reducción del precio	Lealtad del consumidor
Y ₅₅	Tolerancia para reducción de calidad	Lealtad del consumidor

Tabla 2-4 HKCSI. Variables Manifiestas

2.2 Índice Mexicano de Satisfacción de los Usuarios (IMSU)

Hasta el momento las evaluaciones que se han realizado han sido individuales, no se tienen resultados a nivel sectorial. En esta sección se mostraran los resultados de la medición de la satisfacción que hasta el momento se han realizado. También se muestran los resultados de un estudio similar realizado por la Universidad Veracruzana.

Desde 2005, en el departamento de ingenierías de la Universidad Iberoamericana, la Dra. Odette Lobato y su equipo, han trabajado en el desarrollo IMSU-PSM. El objetivo del índice es conocer y registrar sistemáticamente las opiniones de los ciudadanos, referentes a los servicios y programas gubernamentales. En 2006, se realizaron dos pruebas piloto (Lobato *et al.* 2006a; Lobato *et al.* 2006b), que consistieron en la evaluación de la satisfacción de usuarios de: Programa de Abasto Rural *Diconsa* y el Programa de Desarrollo Local *Microrregiones*.

El IMSU-PSM busca construir una “metodología propia para los programas y servicios gubernamentales en México, que toma como punto de partida el conocimiento y la metodología de los indicadores nacionales existentes, en especial del americano ya que cuenta con un modelo y metodología probado en servicios y programas gubernamentales” (Lobato *et al.*, 2006, 5).

El desarrollo del modelo IMSU-PSM, toma como base el modelo ACSI del sector público mostrado anteriormente. Las variables manifiestas y la construcción de los instrumentos, se han realizado a partir de:

- a) Estudio de la documentación sobre el programa
- b) Entrevistas con funcionarios del programa para profundizar en el conocimiento del proceso a evaluar, así como para recibir sus intereses específicos de evaluación.
- c) Realización de entrevistas a profundidad

El modelo general, aplicado en las pruebas piloto se muestra en la Figura 2-10.

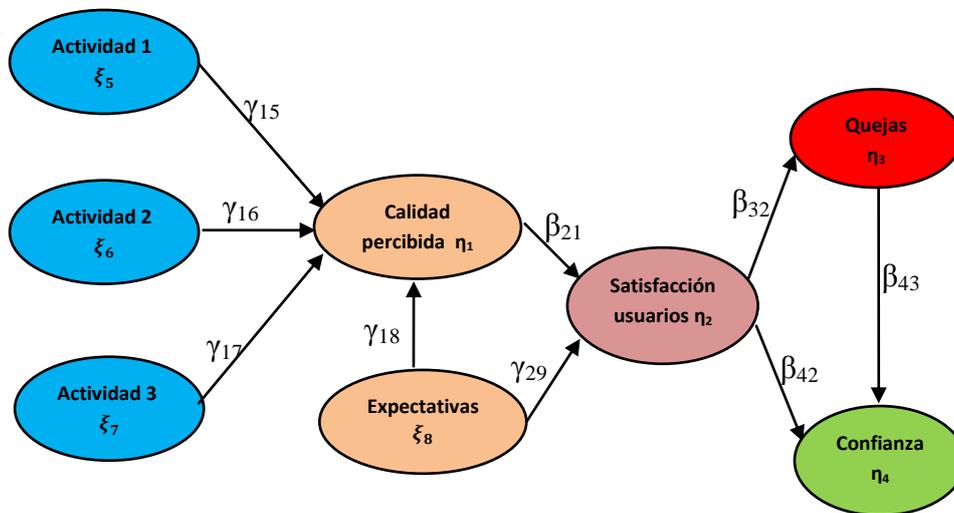


Figura 12 Modelo IMSU sector público

El instrumento está integrado por preguntas cerradas, con escala de 10 puntos. Las preguntas están ancladas en los extremos con adverbios. El 1 siempre representa la opinión más

desfavorable y 10, la más favorable. Otra característica de los instrumentos utilizados, es la inclusión de preguntas socio-demográficas y preguntas para la verificación de la comprensión de la escala.

2.2.1 Programa de Abasto Rural. Diconsa

Para el del Programa de Apoyo Alimentación y Abasto Rural (PAAyAR) caso *Diconsa S.A. de C.V.*, el levantamiento se hizo en el estado de Puebla, por cumplir con los criterios de inclusión establecidos en el diseño de la muestra: nivel de marginación y población atendida por la tienda.

El procedimiento de muestreo adoptado fue en dos etapas. En la primera etapa se seleccionaron 40 tiendas aleatoriamente. En la segunda etapa se seleccionaron 10 usuarios de cada tienda, con muestreo sistemático 2 cada hora, dejando entre la finalización de una entrevista y el inicio de otra 15 min. En la primera etapa la distribución de la selección fue de acuerdo al porcentaje nacional por índice de marginación, dejando: 20% nivel “muy alto” (8 tiendas), 60% “alto” (24 tiendas) y 20% “medio” (8 tiendas). El tamaño de la muestra fue de 400, con aplicación de la encuesta en el exterior de la tienda.

La estimación del modelo se realizó con PLS, a través del programa desarrollado por ACSI. Fue posible estimar, además del modelo global, modelos para mujeres y hombres. La satisfacción estimada fue de 74 puntos, en escala 0-100, para el modelo global, 75 para mujeres y 72 para hombres. (Lobato [1] *et al.*, 2006)

Se mencionan algunos resultados obtenidos en la estimación del modelo global. El modelo desarrollado está conformado por variables latentes: abasto, conveniencia y servicio al

cliente. Estas variables afectan directamente a la calidad percibida. Los coeficientes de trayectoria estimados en el modelo fueron significativos al nivel de 0.05, excepto la trayectoria que va de las expectativas a la calidad percibida. La variable latente resultante con mayor impacto en la calidad percibida es conveniencia, los indicadores de esta variable son precio y calidad. La segunda variable latente con mayor impacto fue abasto, cuyos indicadores son: surtido y ubicación.

2.1.1 Programa de Desarrollo Local. Microrregiones

Por lo que se refiere a la evaluación de la satisfacción del programa de Microrregiones (*Lobato [2] et al. 2006*), se llevaron a cabo 250 entrevistas telefónicas a funcionarios a cargo de proyectos de infraestructura en municipios del territorio nacional. El levantamiento fue exhaustivo, debido al reducido número de elementos en el marco muestral.

El modelo desarrollado, está conformado por variables latentes: proceso, respuesta y asignación de recursos, así como capacidad de gestión del personal. Estas variables afectan directamente a la calidad percibida. Los coeficientes de trayectoria estimados en el modelo fueron significativos al nivel de significancia 0.05, excepto las trayectorias: proceso a calidad percibida, respuesta y asignación de recursos a calidad percibida y quejas a confianza. La variable latente resultante con mayor impacto en la calidad percibida es capacidad de gestión del personal de Microrregiones, cuyos indicadores son eficiencia, seguimiento y utilidad.

Indicador	Variable manifiesta	Variable latente
P_1	Expectativa general de calidad	Expectativas del usuario
P_2	Percepción de surtido de la tienda	Abasto
P_3	Percepción de la ubicación	Abasto
P_4	Percepción del precio de los productos	Conveniencia
P_5	Percepción de la calidad de los productos	Conveniencia
P_6	Percepción de la amabilidad del empleado	Servicio al cliente
P_7	Percepción de horario de servicio	Servicio al cliente
P_9	Evaluación general de calidad	Calidad percibida
P_{10}	Evaluación general de satisfacción	Satisfacción del usuario
P_{11}	Confirmación o no de las expectativas	Satisfacción del usuario
P_{12}	Comparación de la calidad real con la calidad ideal del servicio	Satisfacción del usuario
P_{13}	Si el usuario ha registrado quejas formales	Quejas del usuario
P_{14}	Disposición de recomendar a otros el servicio	Confianza
P_{15}	Disposición a continuar comprando en la tienda	Confianza

Tabla 2-5 IMSU-Diconsa. Variables Manifiestas

Indicador	Variable manifiesta	Variable latente
P_1	Expectativa general de calidad	Expectativas del usuario
P_2	Claridad de objetivos	Proceso
P_3	Claridad de la información	Proceso
P_4	Facilidad de trámite	Proceso
P_5	Transparencia en la resolución	Respuesta y asignación de recursos
P_6	Relevancia del apoyo económico	Respuesta y asignación de recursos
P_7	Oportunidad del recurso	Respuesta y asignación de recursos
P_8	Eficiencia del coordinador	Capacidad de gestión del personal
P_9	Seguimiento del proceso	Capacidad de gestión del personal
P_{10}	Utilidad de las asesorías	Capacidad de gestión del personal
P_{11}	Calidad percibida	Calidad percibida
P_{12}	Satisfacción general	Satisfacción del usuario
P_{13}	Comparación con el nivel de expectativas	Satisfacción del usuario
P_{14}	Comparación con el ideal	Satisfacción del usuario
P_{15}	Si el usuario ha registrado quejas formales	Quejas del usuario
P_{16}	Disposición de recomendar	Confianza
P_{17}	Apoyo esperado del programa en el futuro	Confianza

Tabla 2-6 IMSU-Microrregiones. Variables Manifiestas

2.3 Estudio de Satisfacción Programa de Abasto Rural Diconsa.

Universidad Veracruzana

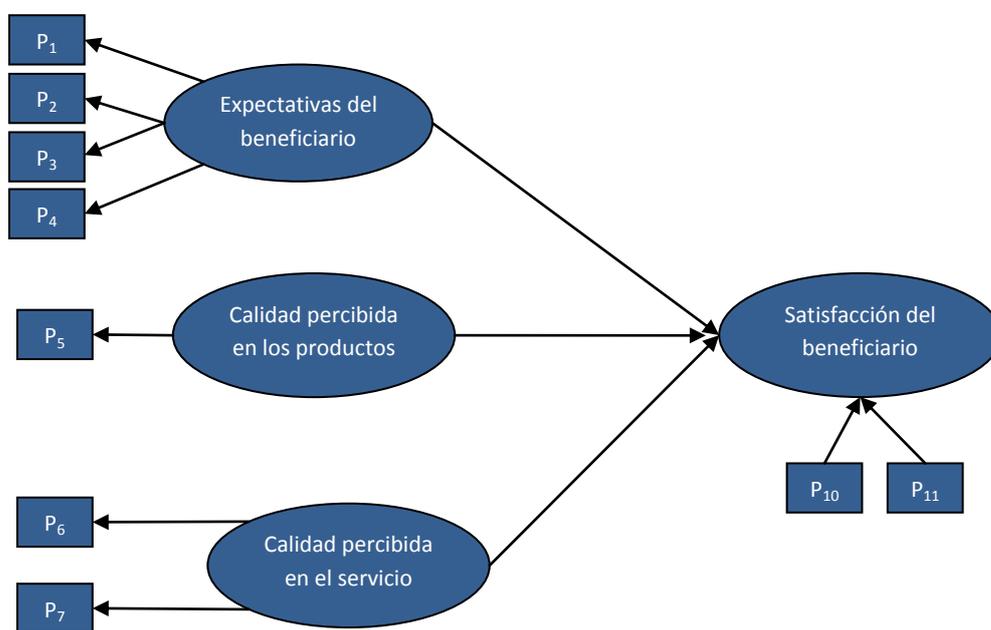
Como se mencionó anteriormente, la construcción del IMSU, ha iniciado su desarrollo en la evaluación de programas sociales implementados por el Gobierno Federal. Estos programas cuentan con indicadores de resultados, gestión y servicios para medir su cobertura, calidad e impacto. Dichas evaluaciones destinan un apartado a la percepción de los beneficiarios. Los resultados presentados en estas mediciones de satisfacción son descriptivos, obtenidos a partir de preguntas directas sobre satisfacción, formuladas a los beneficiarios.

La evaluación citada anteriormente a los usuarios del programa *Diconsa*, es comparable con la realizada en el año 2008 por la Universidad Veracruzana al mismo programa, cuyas características se exponen a continuación (Juárez *et al.* 2008).

El diseño de la muestra, fue probabilístico por conglomerados en cuatro etapas, con estratificación en la primera. La estratificación se realizó por región socioeconómica INEGI, a excepción del D.F. Se eligió un estado por región con probabilidad proporcional al número de tiendas. En la etapa dos, se seleccionaron dos almacenes, nuevamente con probabilidad proporcional. En la etapa 3 se seleccionaron aleatoriamente 27 o 28 tiendas por almacén y en la última etapa se seleccionaron 5 usuarios por tienda, algunos se entrevistaron después de realizar las compras y otros a toque de puerta. El tamaño de la muestra fue de 1677 con representatividad nacional. El método de estimación de parámetros utilizado fue Mínimos Cuadrados Parciales, a través del programa SmartPLS. La escala utilizada en el instrumento final fue Likert, con un rango de 1 a 7 puntos.

En esta evaluación se estimaron tres índices (Juárez *et al.* 2008, 19):

ISBN1. Se basa en la satisfacción como causa directa de la expectativa, la calidad percibida en los productos y la calidad percibida en los servicios, sin considerar interacción entre las variables latentes. La variable que más impacta a la satisfacción es expectativa. El modelo busca explicar la satisfacción en términos de las variables latentes exógenas. Este indicador alcanzó el mayor R^2 , el cual fue de 0.31.

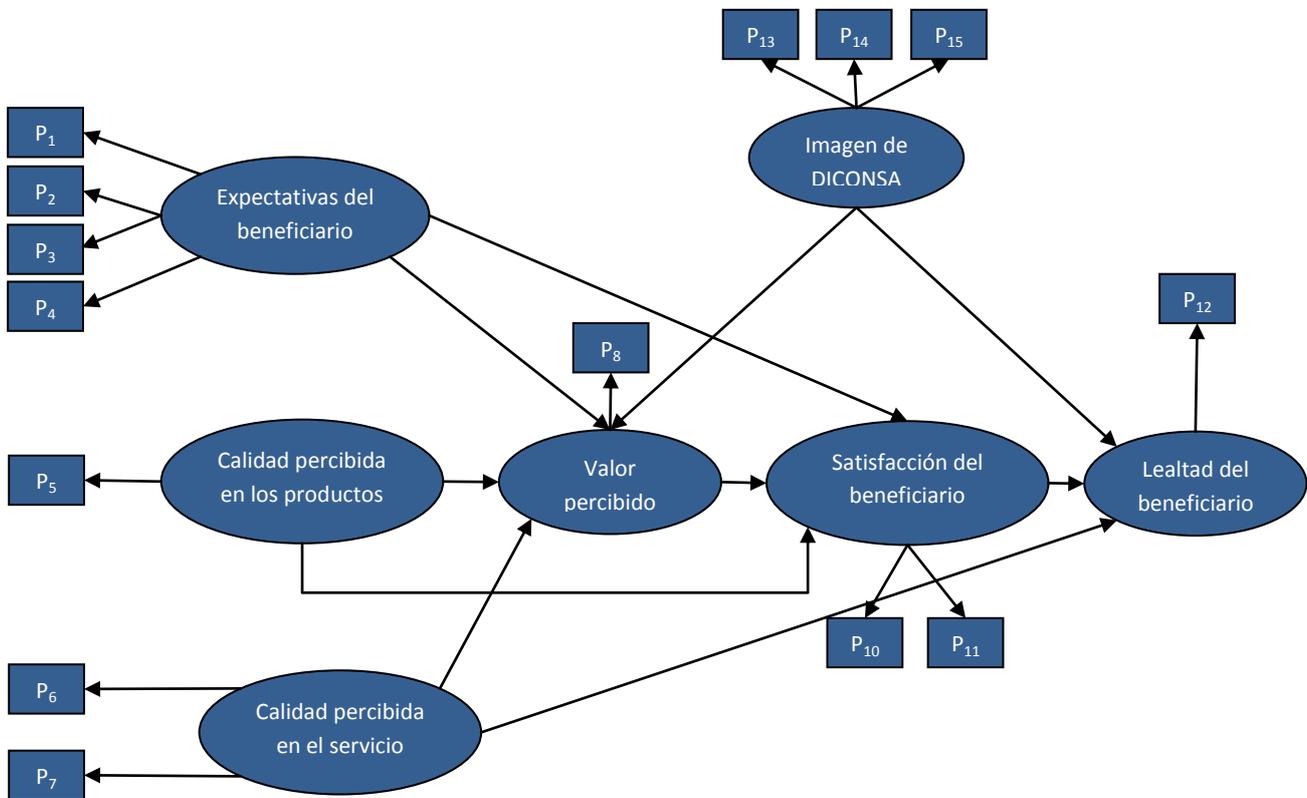


Fuente: Juárez *et al.* 2008, 29

Figura 13 Modelo de causalidad completo ISBN1

ISBN2. Se basa en el ECSI, aquí las expectativas, la calidad percibida de los productos y servicios tienen influencia en la percepción del valor del beneficiario, la cual impacta directamente a la satisfacción. Es de considerar que la expectativa del beneficiario y la calidad percibida en los productos impactan directamente en la satisfacción. La satisfacción se considera causal de la lealtad (que se ve afectada por la calidad percibida en el servicio) del beneficiario hacia la tienda.

El R^2 de este índice fue 0.26. La variable más importante de determinar fue la expectativa de los beneficiarios, seguida del valor percibido (Juárez *et al.* 2008, 28).



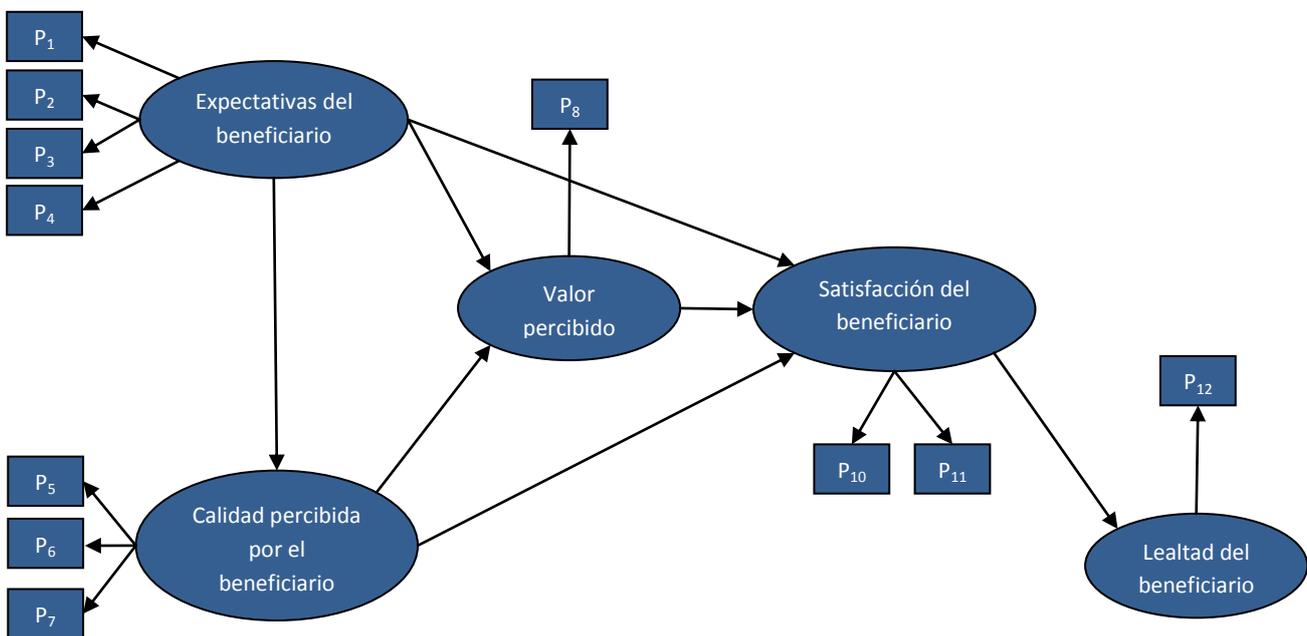
Fuente: Juárez *et al.* 2008, 30

Figura 14 Modelo de causalidad completo ISBN2. Basado en ECSI

ISBN3. Está basado en el modelo ACSI, en donde las expectativas del beneficiario y la calidad percibida influyen directamente sobre la percepción del valor. La expectativa del beneficiario impacta a su percepción de la calidad de los productos y del servicio. El valor percibido tiene una influencia directa sobre la satisfacción e indirecta sobre la lealtad. Finalmente la satisfacción influye directamente sobre la lealtad. El R^2 de este índice fue 0.29. Para el ISB3 la calidad percibida (del producto y del servicio), son los más importantes (Juárez *et al.* 2008, 28)

A nivel nacional, la satisfacción se encontró entre 73 y 78 puntos. Se realizaron estimaciones por estado, en donde se identificó que los estados del norte, Chihuahua y Nuevo León, obtienen índices más altos mientras que Querétaro y Chiapas registraron los valores más bajos,

Se identificó que en los tres índices el impulsor determinante y con signo positivo es la expectativa del beneficiario en términos de percepción del precio, abasto y acceso. Otro impulsor importante es la calidad percibida (producto y servicio) (Juárez *et al.* 2008, 30).



Fuente: Juárez *et al.* 2008, 31

Figura 15 Modelo de causalidad completa ISBN3. Basado en ACSI

Indicador	Variable manifiesta	Variable latente
P_1	Percepción del precio	Expectativa
P_2	Percepción del abasto	Expectativa
P_3	Percepción del acceso a la tienda (física)	Expectativa
P_4	Percepción del acceso a la tienda (horario)	Expectativa
P_5	Percepción de la calidad de los productos	Calidad percibida en el producto
P_6	Percepción amabilidad del encargado	Calidad percibida en el servicio
P_7	Percepción de la rapidez para atender del encargado	Calidad percibida en el servicio
P_8	Relación precio-calidad de los productos	Valor percibido
P_9	Relación precio-calidad de los productos	Valor percibido
P_{10}	Satisfacción global con la tienda	Satisfacción del beneficiario
P_{11}	Percepción con respecto a la tienda ideal	Satisfacción del beneficiario
P_{12}	Recomendación de la tienda	Lealtad
P_{13}	Buen abasto	Imagen
P_{14}	Precios bajos	Imagen
P_{15}	Buen servicio	Imagen

Tabla 2-7 Universidad Veracruzana. Variables manifiestas

2.2 Conclusiones

En este capítulo se han mostrado la estructura de índices de satisfacción utilizados en la actualidad y, sobre los que otros se han basado. Como puede constatarse existen similitudes entre los modelos presentados. Las mayores diferencias están en la inclusión de variables latentes (y sus indicadores) como Imagen, Calidad percibida del servicio y Características del consumidor. Respecto a los indicadores de los constructos, en general, hay similitudes en el contenido, aunque en algunos modelos se cuenta con mayor número de indicadores. Otra diferencia importante es la construcción de la variable latente queja. En el modelo ACSI esta variable cuenta con un indicador, en el modelo ECSI la variable está compuesta por dos

indicadores y tiene la misma escala que el resto de las variables. En el modelo de Hong Kong la variable es nombrada Voz del consumidor y consta de cuatro indicadores.

La formación de los índices nacionales, considera las características económicas de la nación. SCSB registra la satisfacción de clientes de una empresa utilizando su satisfacción respecto a una marca o modelo representativo. ACSI registra la satisfacción del consumidor respecto a varias marcas de una empresa y estos índices se combinan para dar un índice de la empresa. En ambos casos los índices de empresas se combinan para producir un índice de una industria o sector y después combinados dan un índice nacional. Las ponderaciones se basan en el impacto de la empresa, industria o sector en el Producto Interno Bruto. En HKCSI, por la baja importancia de manufactura y la alta importancia de servicios y comercio externo, el índice se basa en los productos y la ponderación se basa en el impacto del producto en el IPC.

Después de la revisión de los modelos y sus indicadores resalta la necesidad de continuar trabajando en la formación del modelo, para el establecimiento del IMSU.

3. Capítulo

Marco Teórico. Estimación de Modelos de Ecuaciones Estructurales

3.1 Introducción

En el Capítulo 1 se mostró que los modelos SEM están conformados por dos sub-modelos, el de medida y el estructural. En el presente capítulo se exponen los diferentes modelos de medida de que se dispone en SEM, su operación y características, según las reglas de correspondencia propuestas para su construcción.

Una vez abordado el modelo de medida, se hace la exposición de los métodos de estimación para modelos SEM, haciendo énfasis en PLS, por ser el método que nos ocupa para este trabajo. Los objetivos, y las características de los enfoques de covarianzas y varianzas, así como las recomendaciones sobre su uso, dadas por los investigadores constituyen el elemento central del capítulo. Finalmente para PLS se describe la operación del método.

3.2 Indicadores en el Modelo de Medida

En los últimos 20 años, el uso de metodologías que evalúan variables no observables a partir de variables observadas, se ha incrementado sustancialmente. Áreas en donde se ha utilizado esta técnica son: psicología, sociología, economía, mercadotecnia, entre otras. Si bien se trata en todos los casos de variables no observables o latentes que son evaluadas a partir de indicadores o variables observables, la dirección de las relaciones causales entre variables latentes y manifiestas difiere según el concepto abordado. De ahí la importancia de resaltar que existen diferentes modelos de medida, y que su operación obedece a un planteamiento teórico particular.

No todas las variables latentes tienen la misma naturaleza, a continuación se describen los tres tipos dados por Bagozzi (1984), “hay tres diferentes tipos de variables no observables: a) variables que son no observables en principio (por ejemplo, términos teóricos); b) variables que son no observables en principio pero, o bien implican conceptos empíricos o pueden ser inferidos a partir de la observación; y c) variables no observables que son definidas en términos de observables” (Haenlein *et al*, 2004, 288).

¿Cómo se muestran, gráficamente, las diferentes variables latentes definidas en el párrafo anterior? Las direcciones de las relaciones establecidas entre una variable latente y sus indicadores, determinan el tipo de variables latente. A estas relaciones se les denomina relaciones epistemológicas o “reglas de correspondencia” (Bagozzi 1984; Fornell y Bookstein 1982 citado en Haenlein *et al*, 2004, 322). Estas reglas de correspondencia implican el uso de indicadores que se clasifican, según la direccionalidad, en reflexivos y formativos.

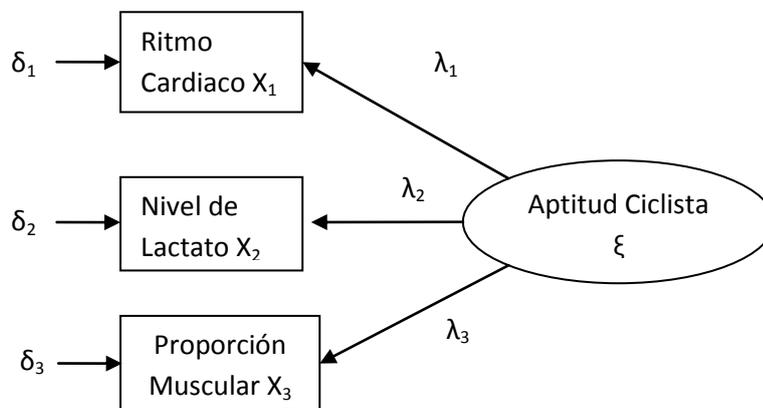
En esta sección se muestran brevemente las características de los dos tipos de indicadores: a) indicadores reflexivos, que dependen de la variable latente y b) indicadores formativos, que causan a la variable latente. Hay que señalar que este trabajo se centrará en el uso de indicadores reflexivos.

3.2.1 Indicador Reflexivo

La regla de correspondencia para el indicador reflexivo es del constructo o variable latente al indicador, e indica que la variable latente es *causa* de los indicadores. “De manera que cambios en la variable latente, se espera sean reflejados en todos los indicadores” (Henseler *et al*, 2009, 289). Este tipo de indicadores deberán ser usados cuando la variable no

observada genera o da lugar a algo que es observado, tal como la personalidad, rasgo o actitud.

En el ejemplo que se muestra (tomado de Henseler *et al.* 2009, 289), la variable no observable aptitud ciclista, causa a las variables observadas X_1, X_2 y X_3 . Un incremento en la variable latente ξ , necesariamente genera un incremento en las variables manifiestas, puesto que las variables manifiestas *reflejan* la variación de la variable latente.



Fuente: Henseler *et al.* 2009, 289

Figura 16 Indicador Reflexivo de Medida

Como se mostró en el Capítulo 1, el modelo de medida con indicador reflexivo es coherente con el Análisis Factorial Confirmatorio (CFA), donde λ_i representaría el efecto esperado de ξ sobre X_i y δ_i es la medida del error para cada indicador $i = 1,2,3$. Se asume que $Cov(\xi, \delta) = 0$, $Cov(\delta_i, \delta_j) = 0$ para $i \neq j$; $E(\delta_i) = 0$ y $Cov(X_i, X_j) \geq 0$ para $i \neq j$ (Bollen, 1984 citado en Lévy *et al.*, 2006, 325).

“Los errores de los indicadores reflexivos pueden (aunque no tienen porque) estar correlacionados” (Diamantopoulos 2001 citado en Lévy *et al*, 2006, 325).

Debido a que los indicadores son causados por la misma variable, es de esperarse que exista una alta correlación entre ellos. Las altas cargas de los factores indican buena representatividad de la variable latente. Otra característica de los indicadores reflexivos es que son intercambiables y si se elimina un ítem, la naturaleza del constructo no cambia. La varianza del constructo, como en el caso de Análisis Factorial, es igual a la comunalidad de los indicadores.

Los indicadores reflexivos pueden ser expresados como una función de la variable latente asociada, matemáticamente:

$$X_1 = \lambda_{x_1}\xi + \delta_1$$

$$X_2 = \lambda_{x_2}\xi + \delta_2$$

$$X_3 = \lambda_{x_3}\xi + \delta_3$$

Utilizando la forma matricial

$$X = \Lambda_x\xi + \delta$$

“Cada indicador, entonces, puede definirse como una función lineal de la variable latente más un término error. La existencia de correlaciones elevadas entre los indicadores aumenta la

consistencia interna del constructo y los análisis de dimensionalidad⁹, fiabilidad y validez lo confirman. Este tipo de modelo es más común en la representación de Modelo de Ecuaciones Estructurales” (Lévy *et al*, 2006, 323).

“Los indicadores reflexivos son típicos en las pruebas de teoría clásicas y en los modelos de análisis factorial; son invocados en un intento de explicar las varianzas o covarianzas observadas” (The ACSI technical staff 2005, 1982, 441). Si el objetivo del estudio es contar la varianza observada, es más recomendable este tipo de indicador.

3.2.2 Indicador Formativo

La regla de correspondencia para el indicador formativo es de los indicadores o variables observables, a la variable latente. Aquí las variables observadas explican a la variable latente, es decir el constructo es *formado* o causado por los indicadores. Por ello “el constructo, en esencia, se expresa como un índice aditivo; el constructo definido está completamente determinado por una combinación lineal de sus indicadores”. (Lévy *et al*, 2006, 323) Algunos ejemplos de indicadores formativos son: cambio poblacional, mezcla de mercadeo, nivel socioeconómico y estrés en la vida.

Si bien este tipo de indicadores es menos visto en los Modelos de Ecuaciones Estructurales, su uso debe ser valorado por la teoría que fundamenta el fenómeno a estudiar.

Para los modelos de evaluación de la satisfacción presentados en el Capítulo 2, los modelos de medida utilizan índices reflexivos, salvo el caso del Índice de Hong Kong (HKCSI), que incorpora indicadores formativos en el modelo. Específicamente la medición del constructo

⁹ Por lo que se refiere a este análisis, es deseable que los constructos o variables latentes sean unidimensionales, es decir, que “el primer valor propio de la matriz de correlaciones sea mucho más grande que uno y el segundo mucho más pequeño” (Tenenhaus 2003, 7).

Características del Consumidor se realiza a partir de un indicador formativo. Las variables manifiestas que integran este constructo y que se han mostrado en la Tabla 2- 4 son: género, preparación académica, edad, ingreso personal, ingreso familiar y tamaño familiar.

Inicialmente el modelo de medida formativo consideraba sólo un indicador, obteniendo un modelo de este tipo

$$\xi \equiv X$$

Este modelo caracterizó muchas de las investigaciones de mercado durante los 60's y 70's en donde el uso de un indicador fue común (Jacob 1978 citado en Diamantopoulos *et al.* 2001, 269).

La incorporación de múltiples indicadores conduce a un modelo de medida en donde la variable latente es función de sus indicadores. La siguiente Figura ilustra un modelo de medida con indicadores formativos.

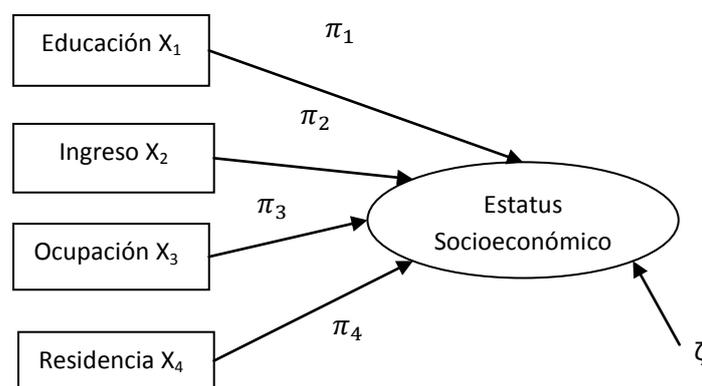


Figura 17 Indicador Formativo de Medida

El diagrama muestra que el estatus socioeconómico está determinado por las variables independientes, educación, ingreso, ocupación y residencia. La omisión de alguna de las variables implica omitir parte de la variable latente y afectar el significado del constructo. “Un cambio en la variable agregada no significa obligatoriamente uno en cada uno de los indicadores; sin embargo, un cambio en los indicadores formativos conllevará a uno en la variable agregada” (Lévy *et al*, 2006, 325). Esta es una de las diferencias entre indicadores formativos y reflexivos.

Diamantopoulos muestra dos modelos matemáticos para establecer la regla de correspondencia entre las variables (Diamantopoulos *et al*. 2001, 271). El primer modelo es:

$$\eta = \pi_{x_1}x_1 + \pi_{x_2}x_2 + \pi_{x_3}x_3 + \pi_{x_4}x_4$$

donde π_i es el parámetro que refleja la contribución de x_i a la variable latente η . Esta expresión es consistente con el modelo de componentes principales. El segundo modelo se diferencia del anterior por la presencia del término error.

$$\eta = \pi_{x_1}x_1 + \pi_{x_2}x_2 + \pi_{x_3}x_3 + \pi_{x_4}x_4 + \zeta$$

A continuación se enumeran otras características de los indicadores formativos:

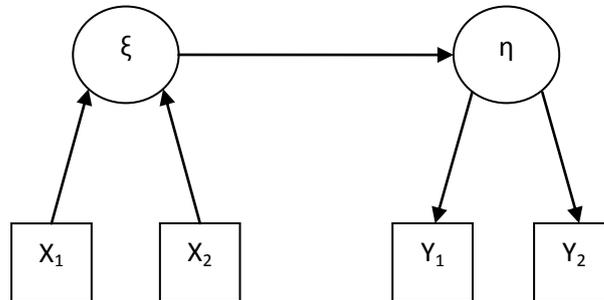
- El incremento de una de las variables observables, conduce a un incremento en la variable latente.

- Entre los indicadores de una misma variable las correlaciones pueden ser positivas, negativas o iguales a cero. Por lo que un cambio en un indicador no significa necesariamente un cambio similar en otro (Haenlein *et al.* 2004, 289).
- “La correlación entre indicadores no está explicada por el modelo de medida, son determinados exógenamente” (Diamantopoulos *et al.* 2001, 271).
- “Los análisis de validez y fiabilidad, no cobran tanta importancia; lo que se vuelve más importante es el poder predictivo” (Lévy *et al.* 2006, 324).
- Son usados para minimizar los residuales en la relación estructural. Si el objetivo del estudio es explicar la varianza de lo abstracto o lo inobservable, este tipo de indicadores proporciona mayor poder (Fornell *et al.* 1982, 441-442).
- La correlación entre el término error y las variable observadas es cero; $cov(X_i, \zeta) = 0$.
Además $E(\zeta) = 0$
- Los modelos de medida con indicadores formativos no son estadísticamente identificados, de manera que se recurre a fijar parámetros para lograr la identificación del modelo. Lo anterior sugiere su inclusión en modelos complejos, en donde haya implicaciones de las variables latentes.

Debido a que el modelo de medida formativo está basado en la regresión múltiple, el tamaño de la muestra e indicadores de multicolinealidad afectan la estabilidad de los coeficientes del indicador, lo cual no ocurre en los indicadores reflexivos (Fornell *et al.* 1982, 442).

Es posible encontrar los dos tipos de indicadores dentro de un Modelo de Ecuaciones Estructurales. La siguiente Figura tomada de Fornell Claes, (1982, 441) muestra gráficamente un modelo en donde la variable latente ξ es causada por sus indicadores x_1 y x_2 (indicadores formativos). Por otro lado la variable latente η es causa de las variables observables y_1 y y_2 .

Además se exhibe una relación causal entre las variables latentes ξ y η . A este tipo de modelos se les conoce como MIMIC (multiple effect indicators for multiple causes).



Fuente: Fornell et al. 1982, p. 441

Figura 18 Modelo MIMIC

3.3 Enfoques para la Estimación de Modelos de Ecuaciones

Estructurales

Hasta este momento se ha centrado la atención en la construcción de SEM a partir del modelo de medida y el modelo estructural. Ahora corresponde revisar los métodos de estimación de parámetros y sus características.

Inicialmente se usó la regresión de los mínimos cuadrados ordinarios (MCO) para la estimación de SEM. Más adelante apareció el método de Máxima Verosimilitud (MV)¹⁰ que, por requerir el cumplimiento de supuestos distribucionales, es reemplazado por los métodos de PLS, Mínimos Cuadrados no Ponderados (ULS), Mínimos Cuadrados Generalizados (GLS) y el Asintóticamente Libre de Distribución (AGL) (Fernández Alarcón 2004, 227).

¹⁰ Máxima Verosimilitud, en adelante MV

Nuevas técnicas para la evaluación de SEM buscan eliminar o minimizar las debilidades de los métodos iniciales. La primera técnica a la que me refiero brevemente es Artificial Neural Network (ANN). “Hackle & Westlund (2000) sostuvo que Artificial Neural Network (ANN)-basado en la técnica SEM podría ser superior a técnicas SEM tradicionales porque puede medir relaciones no lineales mediante el uso de diferentes funciones, actividades y capas de nodos ocultos y puede mejorar estimaciones de ecuación estructural incluso si no todos los supuestos del modelo son satisfechos” (Hsu S-H *et al.* 2006, 356).

Hwang and Takane (2004) han propuesto un método de información completa, llamado Generalized Structured Component Analysis (GSCA), el cual minimiza un criterio global. Finalmente comento el método propuesto por Roderick Mc Donald, quien estima un modelo SEM basado en análisis de componentes principales, con un software basado en covarianzas mediante el uso del criterio de pesos no ponderados (ULS) y restringiendo a cero la varianza del error medida (Mc Donald 1996 citado en Tenenhaus 2003, 2).

En general hay dos enfoques para la estimación de Modelos de Ecuaciones Estructurales: 1) enfoque en la estructura de la covarianza, tal como lo utilizan programas como LISREL, EQS, AMOS, entre otros y 2) enfoque basado en la estructura de las varianzas, también llamado basada en componentes, cuya técnica que se fundamenta en el uso de PLS es la más prominente.

Ambos enfoques buscan la estimación de los parámetros del modelo, pero los objetivos son diferentes. Mientras que para el enfoque basado en covarianzas el objetivo es explicativo (busca poner a prueba un modelo), para PLS es predictivo. Ambos objetivos, explicativo y predictivo, son similares a estos objetivos contemplados en la regresión.

A pesar de que PLS fue creado como una alternativa al enfoque de covarianza, tanto PLS como los métodos basados en el ajuste de covarianzas y mencionados anteriormente, son complementarios en lugar de competitivos (Henseler *et al.* 2009, 296). Esta idea es consistente con el trabajo realizado por Tenenhaus (Tenenhaus 2003, 14) en donde se estima un modelo SEM, basado en ECSI, con varios métodos y se observa que para datos con “buenas” propiedades como uni-dimensionalidad en los constructos, variables con igual escala, correlaciones positivas y Alfas de Cronbach altas, todos los métodos de estimación arrojan resultados muy similares.

El párrafo anterior señala la robustez de los métodos cuando los datos son buenos, sin embargo la obtención buenos datos no es trivial y requiere del desarrollo de trabajos preliminares, es por eso que el enfoque de varianzas toma tal relevancia en las primeras etapas de investigación, en donde es difícil poseer buenos datos.

La elección entre un enfoque y otro debe considerar los objetivos de la investigación y madurez de la misma, las características de los datos, el tamaño de la muestra así como las limitaciones de cada uno de los métodos. El diagrama de flujo que se muestra al final del capítulo, exhibe los elementos a considerar en la elección de un enfoque y otro.

A continuación se describen las características de cada uno de los enfoques. El presente trabajo se centra en la estimación de los parámetros con PLS, ya que por sus características cumple (tal como se mostrará) con dos criterios sugeridos en los Índices de Satisfacción de Consumidores: “1) La técnica de SEM debe determinar el valor del CSI para hacer

comparaciones 2) la técnica de SEM debe exhibir buenas propiedades estadísticas-robustez” (Hsu S-H *et al.* 2006, 356).

3.3.1 Estimación de SEM con el enfoque de covarianzas

Antes de entrar a exponer la estimación bajo el enfoque de covarianzas, es necesario hablar sobre su objetivo. Es orientado por la teoría y enfatiza la transición de modelo exploratorio a modelo confirmatorio. Su uso se recomienda cuando la teoría a priori es fuerte o madura y el objetivo es la validación del modelo. Debido a que no se obtiene el valor de las variables latentes, hay pérdida en la precisión de la predicción, lo cual no es de importancia, puesto que el objetivo es probar las relaciones estructurales entre los conceptos (Hsu S-H *et al.* 2006, 358)

La hipótesis bajo este enfoque es que la diferencia entre la matriz de covarianzas poblacional y la matriz de covarianzas del modelo propuesto sea cero,

$$\Sigma - \Sigma(\theta) = 0$$

o lo que es lo mismo:

$$\Sigma = \Sigma(\theta)$$

Donde Σ es la matriz de covarianzas poblacional y $\Sigma(\theta)$ es la matriz de covarianzas con el modelo propuesto que está en función de los parámetros libres del modelo, representados por θ . Dado que no se conoce la matriz de covarianzas poblacional, se obtienen una matriz de covarianzas muestral S (Manzano 2001, 20).

Es frecuente encontrar que el enfoque de covarianzas, busca minimizar la diferencia entre la matriz de varianzas y covarianza S (de la muestra) y la estimada por el modelo teórico propuesto $\Sigma(\hat{\Theta})$, a fin de obtener exactitud en los parámetros óptimos. “Por consiguiente el proceso de estimación de los parámetros busca reproducir la matriz de covarianzas de las medidas observadas” (Chin & Newsted 1999, 309 citado en Haenlein *et al.* 2004, 290). La matriz de covarianzas está basada en p y q indicadores de medida.

El procedimiento de estimación más aplicado para el cálculo de estructura de covarianzas es el de MV, el cual, requiere cumplir con supuesto de: normalidad multivariada¹¹ de las variables endógenas, independencia en las observaciones, independencia entre las variables exógenas y los errores, así como una correcta especificación del modelo. La función de verosimilitud que busca minimizar la diferencia entre las matrices de covarianzas es

$$F_{ML} = \ln|\Sigma| - \ln|S| + Tr(S\Sigma^{-1}) - (p + q)$$

Existen varias herramientas computacionales para la estimación de los parámetros bajo este enfoque, algunos de ellos son SAS/STAT, EQS, AMOS, SEPATH, COSAN, entre otros, sin dejar de mencionar al más popular, LISREL que fue desarrollado por Jöreskog en 1975 y el cual es, en ocasiones, usado como sinónimo de este enfoque.

El método de MV asume un modelo paramétrico y una familia de distribuciones conjuntas para todas las observaciones, lo que permite realizar pruebas de hipótesis referentes al modelo y a los parámetros, así como el cálculo de los errores estándar.

¹¹ “Normal Multivariada implica que 1) todas variables tienen distribución normal 2) la distribución conjunta de cualquier par de variables es normal bivariada 3) todos los diagramas de dispersión bivariados son lineales y homocedásticos” (Kline 2005, 49).

Para llevar a cabo la estimación de parámetro, se requiere que el modelo esté identificado. Es decir que el número de parámetros a estimar sea al menos igual al número de observaciones $v(v+1)/2$, tal como se indicó en el Capítulo 1.

Los constructos que son medidos con indicadores formativos, no están estadísticamente identificados, de manera que la estimación con Máxima Verosimilitud puede llevar a problemas de identificación severos, implicando covarianzas de cero entre algunos indicadores, correlaciones fuera de rango, y/o la existencia de modelos equivalentes (Fornell & Bookstein, 1982 citado en Haenlein *et al.* 2004, 294). Resultados de este tipo indican que, si bien el proceso iterativo de estimación alcanzó la convergencia, ésta es inadmisibles. Otras causas para este tipo de resultados son: errores de especificación, presencia de observaciones atípicas, una combinación de muestras pequeñas ($N < 100$) y sólo dos indicadores por factor en un modelo de medida, malos valores de inicio y correlaciones en la población extremadamente altas o bajas (Kline 2005, 114).

A continuación se enumeran algunas características que resaltan de SEM basado en covarianzas:

- 1) Permite implementar procedimientos de prueba de hipótesis (rechazar o no el modelo propuesto, comparación entre poblaciones).
- 2) Cálculo de errores estándar para los parámetros del modelo.
- 3) Presenta problemas de convergencia al maximizar la verosimilitud en modelos grandes o pequeños donde el número de variables manifiestas excede el número de casos.

- 4) Se requiere restringir a una constante algunos senderos principalmente para captar la escala de medición, lo cual contribuye a la identificación del modelo.
- 5) Existe un número considerado de índices de ajuste.
- 6) Teóricamente es posible incluir indicadores formativos.
- 7) Indeterminación factorial.
- 8) Especificación de la estructura residual.
- 9) Ajustes idénticos para diferentes modelos hipotéticos.
- 10) Es necesario un conocimiento *a priori*, ya que la prueba χ^2 de ajuste es idéntica para todas las posibles variables no observables que satisfagan la misma estructura de pesos (Fornell *et al*, 1982, 449).
- 11) Precisión estadística en los estimadores, bajo el cumplimiento de supuestos.
- 12) Los estimadores obtenidos tienen propiedades asintóticas para ser insesgados, normales y de alcanzar la cuota de mínima varianza.

El siguiente diagrama de flujo ilustra los pasos para la elaboración y estimación de un Modelo de Ecuaciones Estructurales. Para su elaboración me baso en diagramas encontrados en la literatura del enfoque de covarianzas, así como en Kline (2005, 65).

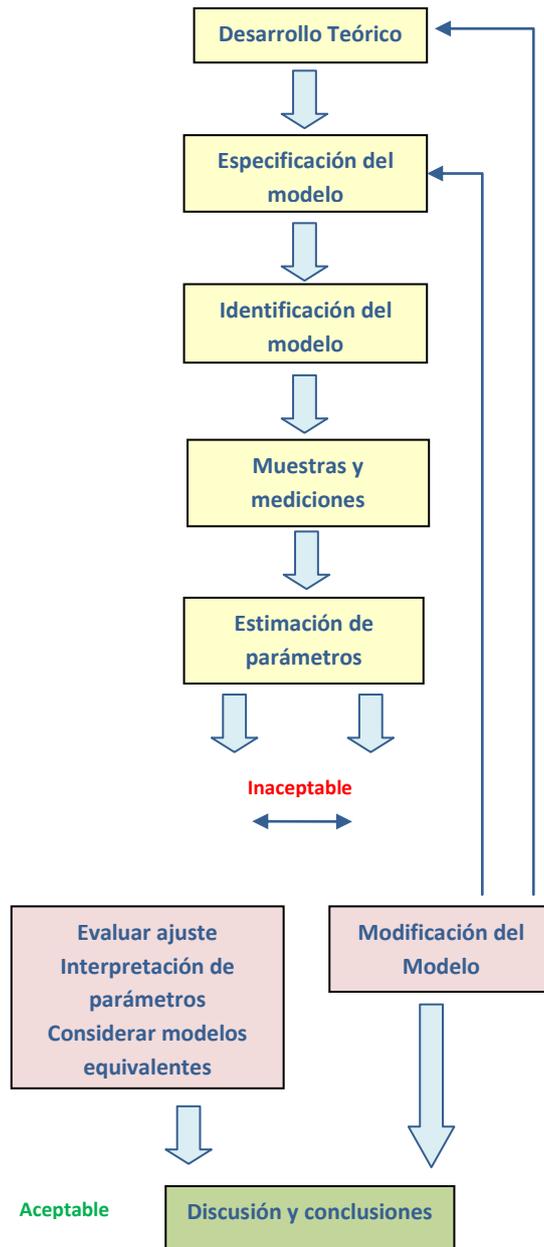


Figura 19 Etapas de elaboración SEM

3.3.1.1 Tamaño de muestra

A diferencia de los tamaños de muestra para medias y proporciones, los cuales son obtenidos con cierto nivel de confianza a partir de cálculos matemáticos, los tamaños de muestra para la estimación de SEM, no se derivan de esta manera. El tamaño de muestra depende del número de parámetros a estimar, así como del método de estimación utilizado. Si bien el tamaño muestral no soporta la identificación del modelo, sí contribuye a la estabilidad de los resultados. El SEM bajo el enfoque de covarianzas requiere muestras grandes. Algunos criterios sugeridos para estimar modelos bajo el enfoque de covarianzas se muestran a continuación.

- El más simple, clasifica las muestras en tres categorías:
 - Pequeñas: si son menores de 100 elementos
 - Medianas: de entre 100 y 200
 - Grandes: mayores de 200

- La estimación de modelos complejos requiere muestras más grandes que los modelos simples, debido a que hay mayor número de efectos a ser estimados. Para modelos complejos se sugiere utilizar muestras grandes. “Con menos de 100 casos, casi cualquier tipo de SEM será imposible de estimar a menos que sea un modelo simple” (Kline 2005, 15).

- Aunque no hay un consenso absoluto en la literatura, acerca de la relación entre el tamaño muestral y la complejidad del modelo se recomienda que el cociente entre el tamaño muestral y el número de parámetros libres sea de 20:1; El cociente 10:1 es, en

muchas ocasiones, un objetivo más práctico, pues determina tamaños muestrales menores que representan ventajas tanto en costo, como en tiempo. Así, un modelo con 20 parámetros requiere como mínimo 200 elementos en la muestra. No se recomienda que el cociente del tamaño muestral entre el número de parámetros esté debajo de 5:1 (Kline 2005, 111).

3.3.1.2 Índices de Ajuste

Existen varios índices para evaluar el nivel de ajuste del modelo Kline (2005, 135) describe aquellos que recomienda reportar para el análisis de un SEM basado en covarianzas.

1) Modelo χ^2

Una medida global es la estadística de la razón de verosimilitud, la cual sigue una distribución asintótica χ^2 .

$$\chi^2 = (n - 1)F_{ML}$$

Donde n es el tamaño de la muestra. Con grados de libertad

$$gl = (p + q)(p + q + 1 - t)$$

Siendo t el número de parámetros libres en el modelo.

La hipótesis nula para esta prueba es que el modelo tiene un ajuste perfecto en la población, de manera que a medida que aumenta el valor de χ^2 el ajuste del modelo es peor. Es deseable en esta prueba que no se rechace la hipótesis nula.

Esta prueba permite evaluar el grado de semejanza entre las matrices S y $\Sigma(\hat{\theta})$. Debido a que este indicador es una función del tamaño de la muestra, así como de la cercanía entre las matrices comparadas, su uso es limitado. Un incremento en el tamaño de la muestra aumenta la probabilidad de rechazar un modelo aún cuando las diferencias entre las matrices sean triviales.

2) RMSEA Steiger-Lind (Root Mean Square Error of Approximation)

Este es un índice de parsimonia ajustado. Dados dos modelos con similar poder explicativo de los datos, se favorece el modelo más simple. RMSEA aproxima a una distribución χ^2 no central, por lo que no requiere una hipótesis nula correcta. La hipótesis nula de esta prueba es que el ajuste del modelo a los datos no es perfecto. Indicadores con valores cercanos a cero muestran un buen ajuste, mientras mayor es el indicador peor es el ajuste del modelo. El modelo es considerado bueno si el RMSEA es menor o igual que 0.05.

$$RMSEA = \sqrt{\frac{F_0}{gl}}$$

$$\text{Donde } F_0 = \max \left[\frac{(N-1)F - gl}{N-1}, 0 \right]$$

Para este índice se obtienen intervalos de confianza al 90%. Se recomienda que el límite superior sea menor a 0.1

3) CFI Bentler (Comparative Fit Index)

Con este indicador se evalúa la mejora relativa en el ajuste del modelo de investigador comparado con el modelo base. El modelo base es independiente, se asume que las covarianzas poblacionales entre las variables observadas son cero. Un buen modelo tendrá un CFI mayor o igual a 0.95.

$$CFI = 1 - \frac{\max(\chi_M^2 - gl_M)}{\max(\chi_B^2 - gl_B)}$$

Donde $\chi_M^2 - gl_M$ estiman el grado de especificación incorrecta en el modelo del investigador y $\chi_B^2 - gl_B$ se refiere al modelo que supone independencia total de las variables. Este último valor es frecuentemente mayor que el del modelo estimado. Para que χ_M^2 sea mayor que χ_B^2 se requiere que el modelo del investigador supere al modelo base o independiente, de otra manera no hay razón para preferir el modelo propuesto (Kline 2005,140)

4) SRMR (Standardized Root Mean Square Residual)

La magnitud en los residuos estandarizados, es otro elemento para valorar el grado de ajuste del modelo. La estandarización de los residuos es una interpretación objetiva, ya que se elimina el efecto producido por la escala de las variables observadas.

Un perfecto ajuste mostrará residuales iguales a cero, por lo que el incremento de los residuales indica empeoramiento en el ajuste del modelo. Valores de SRMR menores a 0.10 son generalmente considerados favorables.

5) Coeficiente de determinación R^2 de variables latentes endógenas

La interpretación de este indicador es análoga a la regresión; indica la cantidad de varianza explicada del constructo por el modelo. Comparaciones entre coeficientes de determinación obtenidos en simulaciones y con datos reales, muestran que bajo el enfoque de covarianzas se obtienen R^2 mayores a las obtenidas bajo el enfoque de varianzas (Hsu S-H. *et al.* 2006, 363). Lo anterior es consistente con la idea de que el enfoque es explicativo.

3.3.2 Estimación del SEM con el enfoque de varianzas (PLS).

La integración de este apartado es de suma importancia para el presente trabajo, el cual busca mostrar la metodología de Mínimos Cuadrados Parciales utilizada en la estimación de SEM. Para la estimación de la aplicación (Capítulo 4), se utilizarán los software SmartPLS (Ringle *et al.* 2005: SmartPLS 2.0 (M3)) y el de ACSI. Hasta el momento el IMSU-PSM ha utilizado, para la estimación de sus modelos, el software desarrollado por ACSI.

A diferencia del enfoque de covarianzas, el objetivo del enfoque de varianzas, es predicción en el análisis causal, sobre todo cuando los modelos son complejos y la teoría no es sólida. Es posible que pueda ser utilizado en análisis confirmatorio, aunque todos los indicadores son considerados útiles para la explicación. La falta de una función de optimización global y con

ello indicadores de ajuste global limita el uso de PLS para probar teorías (Henseler *et al.* 2009, 296-297).

El primero en desarrollar la idea de PLS fue Wold en 1966, en un artículo sobre componentes principales, y donde fue introducido el algoritmo NILES (nonlinear iterative least squares), posteriormente el algoritmo y sus extensiones fue nombrado NIPLAS (nonlinear iterative partial least squares) (Tenenhaus *et al.* 2005, 160).

“PLS ha sido desarrollado principalmente por Herman Wold (una referencia principal es Wold, 1985), por Juan-Bernd Lohmöller (1984, 1987, 1989) para aspectos computacionales y algunos desarrollos teóricos, y por Wynne W, Chin (1998, 1999, 2001) por un nuevo software con interfaz gráfica y mejores técnicas de validación” (Chatelin, *et al.* 2002. 7).

Introducido bajo el nombre de NIPLAS (*nonlinear iterative partial least square*), PLS tienen como propósito maximizar la varianza de las variables dependientes explicada por las independientes. Al igual que en el enfoque de covarianzas, la estructura de un modelo SEM estimado con PLS está integrado por el modelo de medida y el modelo estructural. A esa estructura se agrega otro componente, el peso de las relaciones, que son usadas para estimar los valores de las variables del caso latente (Chin & Newsted, 1999 citado en Heanlein 2004, 290).

Tomando en cuenta las regresiones implicadas en SEM estimadas con PLS, se piensa más como un modelo de senderos predictivo para las variables latentes endógenas que como una red de causalidad. Por lo anterior hay más énfasis en la exactitud de las predicciones que en la

exactitud de la estimación (Esposito *et al.* 2010, 52). En el siguiente apartado se describe la operación del método.

3.3.2.1 Operación del método

PLS es un algoritmo iterativo que resuelve separadamente el modelo de medida y posteriormente en el segundo paso estima los coeficientes de senderos del modelo estructural.

Antes de entrar en la descripción del método es importante identificar el tipo de estandarización requerida para las variables manifiestas según se satisfagan o no las siguientes condiciones, descritos por Chatelin (2002, 7).

1. La escala de las variables manifiestas es comparable
2. La media de las variables manifiestas son interpretables
3. La varianza de las variables manifiestas refleja su importancia

Cuando no se cumple la condición 1 se requiere estandarizar (media 0 y varianza 1), por el contrario, su cumplimiento permite trabajar con los datos originales, sin embargo la estimación de los parámetros depende del cumplimiento de las otras condiciones.

Si no se cumplen las condiciones 2 y 3 se requiere estandarizar (media 0 y varianza 1), para estimar los parámetros. Para la presentación de resultados las variables son re-escaladas a sus unidades de origen.

El cumplimiento de la condición 2 e incumplimiento de la condición 3 requiere estandarizar a varianza uno para la estimación de los parámetros. Para la presentación de resultados las variables son re-escaladas a sus unidades de origen.

El último escenario se refiere al cumplimiento de las condiciones 2 y 3, el donde el uso de las variables originales es requerido.

Para la estimación del modelo de medida, PLS inicia calculando la puntuación de las variables latentes a partir de sus indicadores. La primera estimación se hace a partir de una combinación lineal exacta de sus indicadores y es utilizada por PLS en la sustitución de las variables latentes. Los pesos usados para determinar la puntuación de variables latentes son estimados de manera que se capture la mayor varianza de las variables independientes, las cuales son utilizadas en la predicción de la variable dependiente.

El valor de las variables latentes es, por tanto, calculado a partir de un promedio ponderado de sus indicadores. PLS se basa en el supuesto de que todas las varianzas de las variables observables son útiles y deberían contribuir en la explicación de la variable independiente. Una vez que se tienen puntuaciones para las variables independientes, estas son utilizadas para calcular las relaciones estructurales, a partir de regresiones de mínimos cuadrados ordinarios (Heanlein 2004, 291).

Tal y como lo describe Heanlein (2004, 291), la idea básica de PLS es bastante directa y se puede resumir en los siguientes pasos:

1. Se estiman pesos para las relaciones de los indicadores con sus correspondientes variables latentes.
2. Se calculan puntuaciones de cada variable latente con base a un promedio ponderado de sus indicadores usando los pesos estimados en el paso anterior.
3. Las puntuaciones de las variables latentes obtenidas, se colocan en el modelo estructural para determinar los parámetros de sus relaciones a partir de un conjunto de ecuaciones de regresión.

Los pasos numerados, describen el proceso de estimación del modelo en su totalidad. Los dos primeros resumen la estimación del modelo de medida, mientras que el tercer paso sintetiza la estimación del modelo estructural. Hasta el momento la idea es clara y sencilla, sin embargo es necesario enfocarse en el proceso de determinación de los pesos de los indicadores de las variables latentes. Este es el punto crucial en la estimación de un SEM en donde las fuentes de información son variables latentes cuyo valor depende del peso asignado a cada uno de sus indicadores, basado en el supuesto de que existen indicadores más relevantes que otros, de manera que es deseable que el peso de los indicadores no sea igual.

En PLS la estimación de los valores de las variables latentes, es un procedimiento iterativo, el cual se repite hasta que se obtenga la convergencia, es decir, hasta que el cambio en las estimaciones de los valores externos sea menor a un valor determinado¹². La determinación de los pesos de los indicadores, tomado de Heanlein (2004, 291), así como de Tenenhaus (Tenenhaus *et al* 2005 citado en Henseler *et al.* 2009, 287) se describe a continuación:

1. *Aproximación externa del valor de la variables latente*

¹² Criterio de convergencia establecido por Wold, 1982 (citado por Henseler 2011) $C = \sum_{j,h} |w_{jh}^{(i)} - w_{jh}^{(i-1)}| < 10^{-5}$ donde w_{jh} = peso de la variable manifiesta, j = índice sobre la variable latente, h = índice sobre la variable latente, i = iteración del índice.

Este valor se calcula con el promedio ponderado de los indicadores de la variable latente. El valor se estandariza (media 0 y varianza 1). Cuando el procedimiento está avanzado y lleva algunas iteraciones, los pesos utilizados en el promedio resultan del último paso. Cuando el algoritmo está iniciando y no se dispone de pesos, se utiliza una combinación arbitraria no trivial para la asignación. Henseler (2009, 288) menciona que para modelos de medida reflexivos los pesos se generan a partir de las covarianzas entre los pesos internos de las variables latentes y sus indicadores.

Para variables latentes estandarizadas y con variables manifiestas centradas se tiene

$$Y_j = \sum \tilde{w}_{jh}(x_{jh} - \bar{x}_{jh})$$

su media se denota por

$$\hat{m}_j = \sum \tilde{w}_{jh}\bar{x}_{jh}$$

y la variable latente ξ_j

$$\hat{\xi}_j = \sum \tilde{w}_{jh}x_{jh} = Y_j + \hat{m}_j$$

donde \tilde{w}_{jh} son los pesos externos.

2. *Estimación de los pesos internos*

Los pesos internos son calculados para cada variable latente con el objetivo de reflejar en qué medida variables latentes vecinas están relacionadas con ella. Este cálculo es

una aproximación interna de las mismas puntuaciones de las variables latentes con base en un promedio ponderado de sus variables latentes vecinas. Para este proceso hay tres esquemas distintos de determinar pesos:

a) *Centroid Scheme*, propuesto por *Wold* (1982). Este esquema “utiliza el signo de las correlaciones entre una variable latente – o más precisamente, las puntuaciones externas – y sus variables latentes adyacentes” (*Henseler et al.* 2009, 287). Este esquema muestra inconvenientes cuando las correlaciones son aproximadamente cero debido a que su signo puede cambiar con pequeñas fluctuaciones.

Centroid Scheme es usado como si se adaptara bien a casos donde las variables manifiestas en su bloque están fuertemente correlacionadas. (*Esposito et al.* 2010, 53)

b) *Factor Scheme* propuesto por *Lohmöller* (1989). Este esquema utiliza correlaciones entre las variables latentes.

Este procedimiento es seguido cuando variables manifiestas en su bloque están débilmente correlacionadas (*Esposito et al.* 2010, 53).

c) *Path Weighting Scheme*, propuesto por *Lohmöller* (1989). Obedece el sentido de las relaciones causales establecidas en el modelo de senderos. Resalta la diferencia entre variables predecesoras de ξ_j que son variables latentes que la explican y las que son explicadas por ξ_j . Para las predecesoras los pesos internos equivalen a los coeficientes de regresión de Y_i en la regresión múltiple de Y_j sobre todas las Y_i 's relacionadas a las explicativas de ξ_j . Mientras que si la variable es

sucesora de ξ_j , el peso corresponde a la correlación entre Y_i y Y_j (Chatelin *et al*, 2002. 9).

Esposito (Esposito *et al.* 2010, 53) recomienda marcadamente Path Weighting Scheme.

Los resultados finales, según el método que se utilice, difieren en poco.

Los dos pasos descritos anteriormente muestran el proceso de estimación de pesos en PLS, el resto del procedimiento constituye la iteración del proceso. Es decir, usando la segunda estimación, los pesos externos se modifican, el proceso de estimación interna y externa se repite hasta que el cambio en las estimaciones de los valores externos sea menor a un valor determinado.

Para concluir esta sección hablo, brevemente y sólo de lo disponible en el software a utilizar, de las opciones de tratamiento de los datos perdidos o datos incompletos.

En la mayoría de estudios se enfrenta la situación de valores perdidos y su tratamiento. La presencia de valores perdidos conlleva dificultades en los análisis, además de reducir la potencia estadística, lo cual implica sesgos en las estimaciones. La fuente o patrón de los valores perdidos varían desde aquellos que son completamente al azar a los que son dependientes fuertemente sobre el valor de una variable. Hay dos tipos generales de patrones de valores perdidos, estos son:

- 1) Perdidos al azar (MAR por sus siglas en inglés), el cual se refiere a que la observaciones perdidas sobre una variable difiere de la observada sobre la variable sólo por azar.

- 2) Perdidos completamente al azar (MCAR por sus siglas en inglés), aquí, además del supuesto anterior la presencia del observado contra el perdido sobre la variable no está relacionado con otra variable. Este es el supuesto que comúnmente se hace en los estudios.

Existen varios métodos para el tratamiento de los valores perdidos. Aquí sólo se describen las dos opciones que a la fecha están implementadas en el software SmartPLS.

Case wise replacement: si bien esta presentado como reemplazamiento se trata de una eliminación de los casos con valores perdidos. Esta opción sigue los criterios de métodos listwise y pairwise. En este caso el tamaño de la muestra se ve reducido y las estimaciones se hacen a partir de las observaciones completas.

Mean replacement: es de los métodos más usados y consiste en usar las estimaciones disponibles y llenar los valores perdidos con la media calculada de esas observaciones. Con este método se mantiene el tamaño muestral original, sin embargo sub-estima la varianza y por tanto infla el valor R^2 ajustado. Esta es una buena opción cuando los datos provienen de los dos patrones mencionados (Cordeiro *et al.* 2010, 282).

3.3.2.2 Características del método

Se muestran las características del enfoque de varianzas, las cuales son mencionadas en la mayoría de los artículos que abordan el tema.

Los supuestos distribucionales en las variables aleatorias no son requeridos en este método, como tampoco supuestos sobre la escala de medida. Sin embargo existen supuestos que deben cumplirse, tanto en las relaciones del modelo de medida como del modelo estructural. De los conocidos detrás del modelo de regresión estándar, el supuesto más importante es el

de especificación del predictor, que establece que la parte sistemática de la regresión lineal debe ser igual a la esperanza condicional de la variable dependiente (Henseler *et al.* 2009, 285). Este supuesto reduce la expresión del modelo estructural

$$\xi = B\xi + \zeta$$

a

$$(\xi|\xi) = B\xi$$

De manera que, los residuos no están correlacionados, como tampoco hay correlación entre el residuo de cierta variable latente endógena y sus variables latentes exógenas.

Por lo que se refiere al modelo de medida reflexivo la expresión se reduce a

$$(X_x|\xi) = \Lambda_x\xi$$

La no dependencia de supuestos distribucionales de los datos, permite realizar estimaciones con datos altamente sesgados o con observaciones independientes no aseguradas (Henseler *et al.* 2009, 289).

Una característica importante del método es la consistencia de los estimadores¹³, la cual se ve afectada por la medida del error involucrado en las variables manifiestas. Sin embargo “el coeficiente de senderos estimado a través de PLS converge a los parámetros de la variable latente del modelo [sólo] si ambos, el tamaño de la muestra y el número de indicadores de cada variable latente tiende al infinito” (McDonald 1996, 248 citado en Heanlein 2004, 291).

El permitir y ser deseable que el número de indicadores por variable latente sea infinito constituye una de las principales fortalezas de esta metodología, puesto que en el enfoque de

¹³ Un estimador consistente es aquel que converge en probabilidad al valor real del parámetro que está estimando cuando el tamaño muestral aumenta.

covarianzas el incremento desmedido de los indicadores, puede conducir a un modelo no identificado, ocasionando problemas en la estimación. De la mano de esta característica está la posibilidad de estimar modelos complejos integrados por un buen número de variables latentes y manifiestas, sin generarse problemas en la estimación.

“el dominio natural de los modelos de variables latentes tal como PLS ... es donde el número de variables latentes significativas es pequeño, mucho más pequeño que el número de variables medidas ... y que el número de observaciones” (Wold 1993, 137 citado en Heanlein 2004, 294).

La segunda condición para obtener consistencia en los estimadores, es el tamaño muestral, sobre el cual se habla en la siguiente sección.

Cuando no se logra la consistencia a la larga de los estimadores, PLS tiende a sub-estimar la correlación entre las variables latentes y a sobreestimar los pesos de los indicadores del modelo en el modelo de medida (Heanlein 2004, 292).

Otra de las ventajas subrayada en los artículos es la estimación de modelos estructurales cuyo modelo de medida es formativo, pues si bien este tipo de modelos se pueden estimar bajo el enfoque de covarianzas a través de sus leguajes de programación, es recurrente la obtención de problemas en la estimación. PLS por el contrario estima los modelos con ambos modelos de medida sin problema, salvo en casos con niveles críticos de multicolinealidad en las variables manifiestas.

A continuación se enumeran las características del método PLS, clasificadas en ventajas y desventajas.

Ventajas

1. No requiere supuestos distribucionales.
2. Puede evaluar modelos más complejos sin generar problemas en la estimación (impropia o no convergente), debido a la simplicidad del algoritmo.
3. Puede trabajar datos con pocas observaciones y un número mayor de variables latentes (Henseler *et al.* 2009, 289).
4. Especifica la estimación de variables latentes.
5. Las variables latentes estimadas se pueden interpretar fácilmente.
6. Se puede trabajar con datos de cualquier tipo (nominal, ordinal, de intervalo).
7. Puede estimar modelos con muestras pequeñas.
8. Elimina posibles problemas relacionados con multicolinealidad.
9. Puede estimar modelos tanto formativos como reflexivos.
10. Es robusto ante valores perdidos.

Desventajas

1. No existen, formalmente, pruebas de significancia para los resultados de las estimaciones de los parámetros.
2. Hay un indicador global de ajuste, basado en comunalidades y coeficientes de determinación.
3. La difusión de los programas estadísticos (software) es mucho más confidencial, comparada con aquellos basados en análisis de covarianza (Tenenhaus 2008, 1).

4. El algoritmo PLS es más un algoritmo heurístico que un algoritmo con propiedades bien conocidas (Tenenhaus 2008, 1).
5. La posibilidad de imponer valores o restricciones en los coeficientes de los senderos, no existe en PLS a diferencia de modelos LISREL (Tenenhaus 2008, 1).
6. Existe sesgo en los estimadores. A menudo los pesos externos entre las variables latentes y sus indicadores son sobreestimados, mientras que los pesos internos entre variables latentes son subestimados. Los coeficientes de senderos convergen al valor real sólo si el tamaño muestral y el número de indicadores por variable latente tienden a infinito (Hsu S-H. *et al.* 2006, 356).
7. Si bien PLS puede operar con muestras muy pequeñas (tal es el caso de resultados presentados con simulaciones de 20 observaciones), los estimadores obtenidos a partir de muestras muy pequeñas no son consistentes, de manera que la facilidad de cualquier uso de los resultados es difícil de asegurar.

3.3.2.3 Tamaño muestral

Como se mencionó en el enfoque de covarianza, no hay fórmulas matemáticas para la obtención del tamaño de la muestra. La forma de determinar el tamaño de la muestra es a través del número de parámetros a estimar dentro del modelo. También se usan criterios empíricos desarrollados en el uso de esta metodología.

El tamaño de la muestra influye en la robustez de las pruebas estadísticas, de manera que la recomendación es tener un múltiplo grande del número de constructos en el modelo, pues está basado en regresión lineal. Una regla de dedo para la estimación robusta de coeficientes de senderos en PLS sugiere el máximo entre: diez veces el número de indicadores de la escala con el mayor número de indicadores formativos y diez veces el mayor número de senderos

estructurales dirigidos a un constructo particular (Baclay *et al*, 1995 citado en Henseler *et al*. 2009, 292)

Una de las características resaltadas de PLS es que puede operar con tamaños de muestra *pequeños* (e.g., 200 o menos casos), así como con modelos complejos, sin que ello conlleve a problemas de convergencia y consistencia. Esta característica es apoyada por Sheng-Hsun Hsu (2006, 368) explícitamente en estimaciones de Índices de Satisfacción del Consumidor, así como por Boomsma & Hoogland. (citado en Henseler, 2009, p. 292) Existen investigadores que refutan estas ideas, tal es el caso de los citados en Henseler (2009, 293); Goodhue, Lewis y Thompson, sin embargo ahí mismo se cita a Goodhue, quien reconoce que si bien PLS no tiene características especiales en estimaciones de muestras pequeñas, su uso es aun conveniente en situaciones de modelos complejos y tamaños de muestra más pequeños que los utilizados en el enfoque de covarianzas.

Chin and Newsted (1999 citado en Henseler 2009, 292) presentaron una simulación Monte Carlo en donde concluyen que PLS es capaz de dar información sobre las propiedades de los indicadores con muestras de tamaño 20.

3.3.2.4 Interpretación de resultados

En el desarrollo del Capítulo 1, se mencionó la importancia de determinar adecuadamente las reglas de correspondencia del modelo, puesto que es una de las tres consideraciones metodológicas para la aplicación de PLS, según lo mencionado por Lévy (2006, 322), las cuales se enumeran a continuación:

1. Determinar las reglas de correspondencia en la formación de constructos y en el modelo.
2. Valorar la fiabilidad y validez de las medidas.
3. Interpretación de los coeficientes estructurales, determinando la adecuación del modelo, para la selección de un modelo final.

En esta sección se abordan los puntos dos y tres, de manera que se expongan los indicadores y criterios para la evaluación de los modelos de medida y estructural bajo el enfoque de varianzas.

Debido a que los modelos SEM estimados con PLS a la fecha no han incorporado criterios de bondad de ajuste, investigadores como Chin citado en (Henseler *et al* 2009, 298) y Lévy (2006, 322) subrayan realizar el análisis del modelo en dos etapas:

1. Confiabilidad y validez del modelo de medida
2. Valoración del modelo estructural

El primer punto muestra diferencias si los indicadores son reflexivos o formativos, mientras que el segundo punto sólo se analiza si las puntuaciones de las variables latentes muestran evidencia suficiente de confiabilidad y validez.

Puesto que el enfoque de varianzas está fuertemente orientado a la predicción, la validación del modelo se enfoca principalmente sobre la capacidad predictiva del modelo. (Esposito *et al.* 2010, 56)

1. Confiabilidad y validez del modelo de medida

a) Reflexivo

Dado que una variable latente debe explicar sustancialmente parte de la varianza de sus indicadores (al menos 50%), la *confiabilidad individual de cada indicador*, “se evalúa mediante examen de las cargas o las correlaciones simples de las medidas con su respectivo constructo. Una regla general es aceptar ítems con cargas estandarizadas iguales o superiores a 0.707 (Barclay *et a.* 1995), lo que implica más varianza compartida entre el constructo y sus medias, que varianza del error (Carmines y Zeller, 1979)” (Lévy 2006, 330).

En Henseler (2009, 299) se cita la recomendación de psicómetras como Churchill (1979), para eliminar indicadores reflexivos con pesos estandarizados menores a 0.4. Se sugiere, debido a que los estimadores obtenidos con PLS son consistentes a la larga, eliminar indicadores cuando su confiabilidad es baja y su eliminación genera mejora en la confiabilidad compuesta (indicador que se detalla adelante).

La confiabilidad de una variable latente muestra *consistencia interna* a partir de sus indicadores o variables observables. A este elemento también se hace referencia con el concepto de unidimensional, en el sentido de análisis factorial. Para modelos de medida reflexivo existen varias herramientas para verificar la unidimensional del bloque de variables manifiestas, Tenenhaus (2005, 163) menciona el uso de análisis de componentes principales, el cálculo de Alfa de Cronbach y la Confiabilidad Compuesta o Dillon-Goldstein's.

Sobre el análisis de Componentes Principales de un bloque de variables manifiestas se dice que es unidimensional si el primer valor propio de la matriz de correlaciones de un bloque de

variables manifiestas es mayor que uno y el segundo es menor a uno, o al menos muy lejos del primer valor propio. La recomendación es que el primer componente principal este construido con las correlaciones positivas de todos o al menos la mayoría de las variables latentes. Existen problemas con correlaciones negativas de los indicadores con el componente principal, la sugerencia es eliminar ese indicador que es inadecuado para medir la variable latente (Tenenhaus *et al.* 2005, 163).

Tradicionalmente la consistencia interna del constructo se determina por el Alfa de Cronbach, que “mide el grado en que las respuestas son coherentes a través de las preguntas de una misma medida” (Kline 2005, p. 59).

El Alfa de Cronbach muestra la confiabilidad basada en la correlación entre los indicadores del constructo, pero se asume que los indicadores son igualmente confiables. Debido a que este indicador tiende a sub-estimar severamente la confiabilidad de la consistencia interna de los modelo SEM, se recomienda utilizar diferentes medidas, tal como la Confiabilidad Compuesta (Henseler *et al.* 2009, 299).

$$\alpha = \frac{N \cdot \bar{r}}{(1 + (N - 1) \cdot \bar{r})}$$

Donde N es el número de variables manifiestas y \bar{r} es el promedio de la correlación.

La Confiabilidad Compuesta fue desarrollada por Werts, Linn y Jöreskog en 1974. Esta medida no asume equivalencia entre las medidas, por el contrario prioriza indicadores, lo que lo hace un compuesto confiable. Se interpreta de la misma manera que el Alfa de Cronbach. Un nivel aceptable para la consistencia interna en los primeras etapas de investigación es 0.70

y valores de 0.80 o 0.90 para etapas más avanzadas. Valores de 0.60 indican falta de confiabilidad (Henseler *et al.* 2009, 299). Este indicador se determina a partir de la siguiente expresión:

$$\rho_c = \frac{(\sum \lambda_i)^2}{(\sum \lambda_i)^2 + \sum_i var(\varepsilon_i)}$$

Donde λ_i representa la carga factorial del indicador y la $var(\varepsilon_i) = 1 - \lambda_i^2$ la varianza del error.

Chin (1998 citado en Tenenhaus *et al.* 2005, 51) considera que “La ρ de Dillon_Goldstein es mejor indicador que el Alfa de Cronbach”.

La validez de una puntuación se refiere a la solvencia de las inferencias basadas en las puntuaciones, esto es, si las puntuaciones miden lo que ellos suponen medir, y que además no miden lo que no suponen medir. La confiabilidad de una puntuación es necesaria pero insuficiente requerimiento para la validez. Para el caso de la validez del constructo, se busca que el constructo hipotético mida lo que el investigador espera (Kline 2005, 61).

Por lo que se refiere a la *validez convergente*, esta característica significa que un conjunto de indicadores representan a un constructo y que además es el mismo constructo, lo cual se demuestra a través de la unidimensional. La evaluación de tal característica se hace a través de la comunalidad que, como se mencionó en el Capítulo 1 es la cantidad de varianza obtenida por un constructo debida a sus indicadores en relación a la varianza total (varianza compartida más varianza del error). La media de comunalidad de cada constructo y para todo el modelo, puede ser calculada con AVE (Average Variance Extracted). Una variable latente

con un AVE de al menos 0.5 indica capacidad del constructo para explicar más de la mitad de la varianza de sus indicadores en promedio (Henseler *et al.* 2009, 299).

$$AVE = \frac{\sum_{i=1}^i \lambda_i^2}{\sum_{i=1}^i \lambda_i^2 + \sum_{i=1}^i var(\varepsilon_i)}$$

Donde λ_i representa la carga factorial del indicador y la $var(\varepsilon_i) = 1 - \lambda_i^2$ la varianza del error. Como puede observarse el AVE es el promedio de las comunalidades, por constructo.

Chin (2010, 674) menciona que para asumir validez convergente, además de solicitar pesos grandes (superiores a 0.7) es necesario que los pesos de los indicadores sean similares, es decir, que el rango entre los pesos pertenecientes al constructo sea estrecho (tal como 0.7 a 0.9). Cuando el rango es amplio debe plantarse si las medidas son verdaderamente un conjunto homogéneo que captura principalmente el fenómeno de interés.

La *validez discriminante* es una característica complementaria de la validez convergente, y se refiere a que dos variables conceptualmente diferentes deben exhibir sus diferencias. En PLS hay dos criterios para la validez discriminante, los cuales se muestran a continuación.

El indicador AVE puede ser utilizado para medir, también, la validez discriminante entre constructos. Fornell y Lacker (1981, citado en Henseler *et al.* 2009, 300) sugieren que el AVE de cada variable latente sea superior que el cuadrado de la correlación con todas las otras variables latentes”. O bien, la raíz cuadrada del AVE de cada variable latente sea superior a la correlación con todas las otras variables latentes

$$\sqrt{AVE(\eta_i)} > Corr(\eta_i, \eta_j) \text{ y } Corr(\eta_i, \eta_j) < \sqrt{AVE(\eta_j)}$$

Esta condición exhibe, esencialmente, que si un constructo está más correlacionado con otro constructo que con sus propios indicadores de medida, hay la posibilidad de que los constructos compartan el mismo tipo de indicadores y que no sean conceptualmente diferentes. Alternativamente indica que ambos grupos de indicadores realizan un trabajo pobre en la diferenciación de los constructos propuestos (Chin 2010, 670).

El segundo criterio para la validez discriminante es “el peso de cada indicador, es esperado para ser más grande que todos los de sus pesos cruzados” (Chin 1998; Götz *et al.* 2009 citado en Henseler *et al.* 2009, 300). Es decir, el peso de un indicador asociado a su variable latente debe ser mayor que los pesos asociados al resto de las variables latentes. Lo contrario implica que el indicador observado es incapaz de discriminar si pertenece al constructo al que intenta medir o a otro.

Chin (1998b citado en Chin 2010, 675) señala que especialmente debe cumplirse el criterio indicado en el párrafo anterior, sin embargo también se espera que al revisar una variable latente (columna) los pesos de sus indicadores sean mayores que los pesos cruzados.

En caso de que un modelo de medida no cumpla con suficiencia los criterios mencionados, el investigador debería excluir indicadores y revisar el modelo de senderos (Henseler *et al.* 2009, 300).

b) Formativo

La validación de este modelo de medida, se menciona brevemente puesto que los modelos que se evaluarán no son de este tipo. Para profundizar en el tema se recomienda revisar los

artículos citados en el cuerpo de este apartado, de donde se basa la exposición de este segmento.

Bollen y Bagozzi (Bollen 1989, 222 y Bagozzi 1994, 333 citados en Diamantopoulos *et al.* 2001, 271) resaltan que para modelos de medida formativos, el cumplimiento de confiabilidad (consistencia interna) y validación del constructo (validación convergente y discriminante) no son relevantes. En el modelo formativo cada variable manifiesta representa una dimensión diferente del concepto estudiado.

La validación de los modelos formativos según lo expuesto por Henseler (2009, 301) debe darse primero a partir de una justificación teórica y experta y, en segundo lugar, debe comprender un análisis estadístico en dos niveles:

1. Nivel de constructo
2. Nivel del indicador

A nivel de constructo es importante determinar si el indicador formativo lleva el significador previsto y por lo tanto presenta un comportamiento de acuerdo a las hipótesis. Es importante resaltar que en los modelos formativos la variable latente está determinada por sus indicadores, por lo tanto es importante una definición completa para evitar dejar fuera indicadores relevantes. (Diamantopoulos *et al.* 2001, 271) Las relaciones establecidas de acuerdo a la teoría, entre los constructos, deben ser fuertes y significativas.

Otro elemento de importancia es el cálculo del error de constructo v , el cual representa la parte del constructo que no ha sido capturada. Para su estimación hay que obtener la validación externa $1 - Var(v)$. Este indicador debe ser del orden del 0.8 como mínimo, lo cual indica que el indicador formativo carga con el 80% del significado previsto, sin embargo hay que considerar el campo de investigación.

A nivel del indicador se busca conocer su contribución de acuerdo con el significado previsto. Cuando se describieron los modelos de medida, se mencionó que a diferencia de los modelos reflexivos, en los modelos formativos los indicadores deben cubrir enteramente a la variable latente. Los dos casos en los que el investigador debe examinar la inclusión de un indicador son: cuando el indicador *no* tiene un impacto *significativo* sobre el índice formativo y cuando se observa *multicolinealidad* (existen indicadores que miden lo mismo, hay redundancia). En el caso de la existencia de multicolinealidad es recomendable el uso de regresión PLS para la estimación de los pesos externos en el modelo formativo, en lugar de la regresión de Mínimos Cuadrados Ordinarios. (Esposito *et al.* 2010, 54) Esta recomendación se hace extensiva cuando hay puntuaciones perdidas de variables latentes, variables latentes altamente correlacionadas, un número limitado de unidades con referencia al número de predictores.

La significancia del impacto se determina con métodos no paramétricos tal como Bootstrap o Jackknife. La multicolinealidad en estos modelos obedece a la regresión múltiple se calcula con el VIF (variance inflation factor), la regla de dedo indica que valores con un VIF superior al 10 muestran alto grado de multicolinealidad. “En caso de multicolinealidad el peso de los estimadores puede ser distorsionado” (Henseler *et al.* 2009, 303).

Los investigadores sugieren no eliminar indicadores a partir únicamente de los resultados estadísticos. Si la justificación conceptual lo aprueba deben conservarse indicadores significativos y no significativos, puesto que se corre el riesgo de modificar la naturaleza del constructo. La inclusión de indicadores no significativos difícilmente altera las estimaciones, sin embargo un número excesivo de indicadores es indeseable porque incrementa el número de parámetros a estimar, además de aumentar los costos.

Hasta el momento sólo se ha considerado la evaluación del modelo de medida. Como se mencionó anteriormente, sólo la validación del modelo de medida conducirá a la estimación del modelo estructural. Hay que resaltar que bajo el enfoque de varianzas, cuyo objetivo es predictivo, y que es principalmente recomendado para las etapas tempranas de investigación, es posible que existan indicadores que no cumplen con los criterios de confiabilidad y validez que se requiere. Lo anterior sugiere verificar el cumplimiento de los criterios, y evaluar eliminar indicadores.

Como se ha expuesto, el tipo de validación del modelo de medida depende del tipo de las reglas de correspondencia establecidas, ya sea formativo o reflexivo.

El completo análisis del modelos en diferentes etapas de investigación, contribuye a lograr un modelo general con deseables características de validez y confiabilidad, que contribuya al perfeccionamiento del modelo y alternativamente la comparación de estimaciones bajo los dos enfoques.

2. Valoración del modelo estructural

Para realizar la valoración del modelo estructural se requiere un resultado satisfactorio obtenido en la confiabilidad y validez del modelo de medida.

Como se ha mencionado anteriormente, el método PLS hace énfasis en el análisis de la varianza explicada. El poder predictivo es evaluado con el R^2 de cada variable latente endógena, cuya interpretación es análoga a la regresión. El R^2 indica la cantidad de varianza explicada del constructo por el modelo.

Chin (1998 citado Henseler *et al.* 2009, 303), describe criterios para el R^2 . Modelos estimados con PLS cuyo R^2 de 0.67 se considera sustancial, de 0.33 es moderado y de 0.19 es pobre. También señala aceptables R^2 moderadas en los casos en donde una variable latente endógena es explicada por pocas, uno o dos, variables latentes exógenas. En los casos en que el número de variables latentes exógenas es mayor, se esperan por lo menos R^2 sustanciales.

Como se observa la estimación del modelo estructural se realiza con regresiones independientes. Esposito señala que sería una sabia elección reemplazar esta práctica por análisis de senderos sobre las puntuaciones de las variables latentes, considerando simultáneamente todas las relaciones (Esposito *et al.* 2010, 57).

Los coeficientes de senderos se interpretan como coeficientes estandarizados de regresión.

Una validación empírica del modelo estructural se obtiene cuando el signo de los coeficientes de senderos soporta las relaciones teóricas propuestas entre las variables latentes.

Una medida para determinar el tamaño del impacto de un sendero propuesto en el modelo se obtiene con el siguiente cálculo:

$$f^2 = \frac{R_{incluido}^2 - R_{excluido}^2}{1 - R_{incluido}^2}$$

Donde $R_{incluido}^2$ es el R^2 obtenido sobre la variable latente cuando el predictor es usado y de manera similar $R_{excluido}^2$ cuando el predictor no es usado. Los criterios encontrados para ver si el predictor tiene un efecto pequeño, mediano o grande en el nivel estructural son 0.02, 0.15 y 0.35, respectivamente (Cohen (1988) citado en Chin 2010, 675).

Evaluación de precisión de los estimadores con métodos no paramétricos

La construcción de intervalos de confianza para los parámetros estimados con PLS, con el objetivo de hacer inferencia estadística es posible con métodos no paramétricos como Bootstrap y Jack-knife.

Bootstrap

Este método de re muestreo fue desarrollado por B. Efron a finales de los 70's. Hay dos tipos de Bootstrap 1) no paramétrico y 2) paramétrico.

En el primer caso la técnica genera “estimación de la forma, extensión y el sesgo de la distribución de la muestra de un estadístico específico. Bootstrap trata a la muestra observada como si ésta representara a la población” (Henseler *et al.* 2009, 305).

“Generalmente se asume sólo que la distribución de la muestra tiene la misma forma básica que la distribución de la población” (Kline 2005, 42).

El método consiste en obtener N muestras aleatorias artificiales con n observaciones cada una. El número de observaciones, se sugiere sea igual al número de observaciones en la muestra original. Cada observación de la muestra original es igualmente probable de ser elegida en la muestra artificial y puede estar repetida, puesto que la selección se hace con reemplazo.

“Errores estándar son generalmente estimados en este método como la desviación estándar en la distribución muestral empírica del mismo estimador, a través de las muestras generadas” (Kline 2005, 42).

Bootstrap permite probar la hipótesis

$$H_0: w = 0$$

$$H_1: w \neq 0$$

donde w representa el parámetro estimado. Los grados de libertad son $m+n-2$, m es el número de estimadores para w en la muestra original (1), y n el número de estimadores Bootstrap para w .

Chin (1998 citado en Henseler et al. 2009, 306) propone usar el siguiente estadístico t , para PLS:

$$t_{emp} = \frac{w}{se(w)}$$

Donde t_{emp} representa el valor empírico t

w coeficiente de sendero original estimado en PLS

$se(w)$ error estándar del coeficiente de sendero original, obtenido con Bootstrap

Las tablas de distribución *t-Student* proporcionan un valor crítico, para un nivel de confianza determinado y sus respectivos grados de libertad.

Es recomendable obtener, el intervalo de confianza de los parámetros. Si el intervalo de confianza no incluye al cero, entonces la hipótesis nula se rechaza. Hay que señalar que para

poder realizar el Bootstrap no paramétrico es necesario contar con la base de datos total (que no esté condensada en la matriz de varianzas y covarianzas).

Para el Bootstrap paramétrico, es posible realizar la estimación con la información condensada, puesto que las muestras aleatorias se obtienen a partir de la función de distribución de probabilidad con parámetros especificados por el investigador.

Finalmente se mencionan las opciones disponibles en el software SmartPLS para el manejo del signo, el cual puede cambiar arbitrariamente, en el cálculo de pesos externos durante el proceso de re muestreo. Lo anterior implica también que las cargas y la estimación de los coeficientes, en el re muestreo, muestren diferencias arbitrarias referentes a los obtenidos en la muestra original. Es necesario hacer comparables los parámetros de una muestra a otra (Tenenhaus *et al.* 2005, 177). Las opciones disponibles en SmartPLS son:

- *No sign changes*: como su nombre lo indica durante el proceso de re muestreo no hay compensación para ningún tipo de cambio de signo. Esta opción no se recomienda porque conduce a errores estándar grandes y por ende *radios t* bajos.
- *Individual sign changes*: para esta opción se dan cambios en el signo de cada re muestreo consistente con los signos de la muestra original. Este es un buen procedimiento cuando todos los signos del mismo bloque sean iguales, al nivel de la muestra original.

- *Construct level changes*: aquí el vector de pesos de cada variable latente en cada re muestreo es comparado con el correspondiente vector de pesos en la muestra original. El signo de los pesos externos y el de las cargas es cambiado si

$$\left| \sum_h (L_{jh}^S - L_{jh}^R) \right| > \left| \sum_h (L_{jh}^S + L_{jh}^R) \right|$$

Donde L_{jh}^S es el peso estimado de la h-ésima variable manifiesta sobre la j-ésima variable latente de la muestra original y L_{jh}^R es el peso estimado de la h-ésima variable manifiesta sobre la j-ésima variable latente de una muestra. Esta opción proporciona el mismo resultado que la de Individual sign changes, cuando los cambios de signo de las cargas ocurren para todas las variables manifiestas.

Jack-knife

Consiste en generar n sub-muestras del la muestra original. Cada sub-muestra consta de un elemento menos que la anterior, de manera que se pueden identificar observaciones que modifican drásticamente el resultado. Se hace análisis estadístico de cada sub-muestra, se calculan estimadores y se obtienen intervalos de confianza robustos. Con los n resultados se estima la variabilidad del estimador.

Esta prueba permite calcular las t de Student de las cargas factoriales y de los pesos.

Stone-Geisser's Q^2

La capacidad predictiva del modelo es otro elemento a considerar del modelo estructural. La medida predominante para esta característica es Stone-Geisser's Q^2 (Stone 1974; Geisser

1975, citado en Chin 2010, 680), el cual puede ser medido utilizando el procedimiento *Blindfolding*¹⁴ (propuesto por Herman Wold).

Este criterio se refiere a que el modelo debe tener la capacidad de predecir los indicadores reflexivos de las variables latentes endógenas. Geisser (1975, 320 citado en Chin 2010, 679) subraya que la predicción de las variables observables es más relevante que la estimación de los parámetros de los constructos.

Si el valor en la validación cruzada (CV), obtenido del procedimiento, de una variable latente endógena es mayor que cero (sobre todo la redundancia en lugar de la comunalidad) sus variables explicativas proporcionan relevancia predictiva (Henseler 2009, 305).

La redundancia, es un indicador exclusivo de las variables latentes endógenas que consiste en, determinar la capacidad del modelo para predecir las variables manifiestas de las variables latentes que están indirectamente conectadas. Su cálculo está determinado como sigue:

Realizando la regresión de la variable manifiesta sobre su variable latente estandarizada $x_{ij} = aY_j + b + error$

Haciendo la regresión de Y_j sobre sus variables latentes explicativas y dejando \hat{Y}_j para ser el estimador de Y_j .

$$Redundancia = \frac{Var(a\hat{Y}_j + b)}{Var(x_{ih})} = \frac{a^2 Var(\hat{Y}_j)}{Var(x_{ih})}$$

¹⁴ Los detalles de la operación del procedimiento pueden consultarse en Tenenhaus *et al.* 2005, 174, entre otros.

Al igual que en el tamaño del efecto f^2 mencionado anteriormente, el impacto relativo de la relevancia predictiva se puede evaluar con el q^2 . Los criterios son iguales que los descritos en f^2 .

$$q^2 = \frac{Q_{incluido}^2 - Q_{excluido}^2}{1 - Q_{incluido}^2}$$

3. Ajuste Global

Hasta el momento se han presentado indicadores de evaluación parcial. El enfoque basado en covarianzas, cuenta con diversas propuestas de indicadores de bondad de ajuste del modelo. El enfoque de varianzas recientemente incorporó un criterio de ajuste global, este criterio, *GoF*, fue propuesto por Tenenhaus en 2004 (Chin 2010, 680). “Tal índice ha sido desarrollado con el fin de tener en cuenta el rendimiento del modelo, en la medición y el modelo estructural y por lo tanto proporciona una medida única para la predicción del rendimiento global del modelo. Por esta razón el *GoF* es obtenido con la media geométrica del índice de comunalidad promedio y el promedio del valor R^2 ” (Esposito *et al.* 2010, 58).

Como el indicador incorpora la comunalidad promedio, es conceptualmente apropiado para modelos con indicadores reflexivos. En el caso de modelos con indicadores formativos, la comunalidad puede ser calculada e interpretada, en tal caso se esperan comunalidades bajas y R^2 más grandes en comparación con modelos con indicadores reflexivos. El *GoF* puede ser utilizado en modelo con indicadores formativos, para propósitos prácticos, puesto que proporciona una medida de ajuste sobre el modelo (Esposito *et al.* 2010, 58).

$$GoF = \sqrt{Com \times \overline{R^2}}$$

Donde

$$\overline{Com} = \frac{1}{\sum_{j:p_j>1} p_j} \sum_{j:p_j>1} p_j AVE$$

$$\overline{R^2} = \frac{\sum_{j=1}^J R^2(\hat{\xi}_j; \hat{\xi}_{q;\xi_{q \rightarrow \xi_j}})}{J}$$

Con J igual al total de las variables latentes endógenas.

PLS posee actualmente un indicador de ajuste global. Debido a que el objetivo de este enfoque es predictivo y no existe una hipótesis global acerca del modelo, no se tiene indicadores de bondad de ajuste. Otros elementos a considerar en la evaluación del modelo estructural son las R^2 de las variables latentes endógenas, así como la significancia estadística de los coeficientes de senderos. Para el caso del software SmartPLS, sólo tiene incorporado el muestreo con bootstrap. El indicador de ajuste global GoF no está incorporado en SmartPLS.

3.3.2.5 Conclusiones

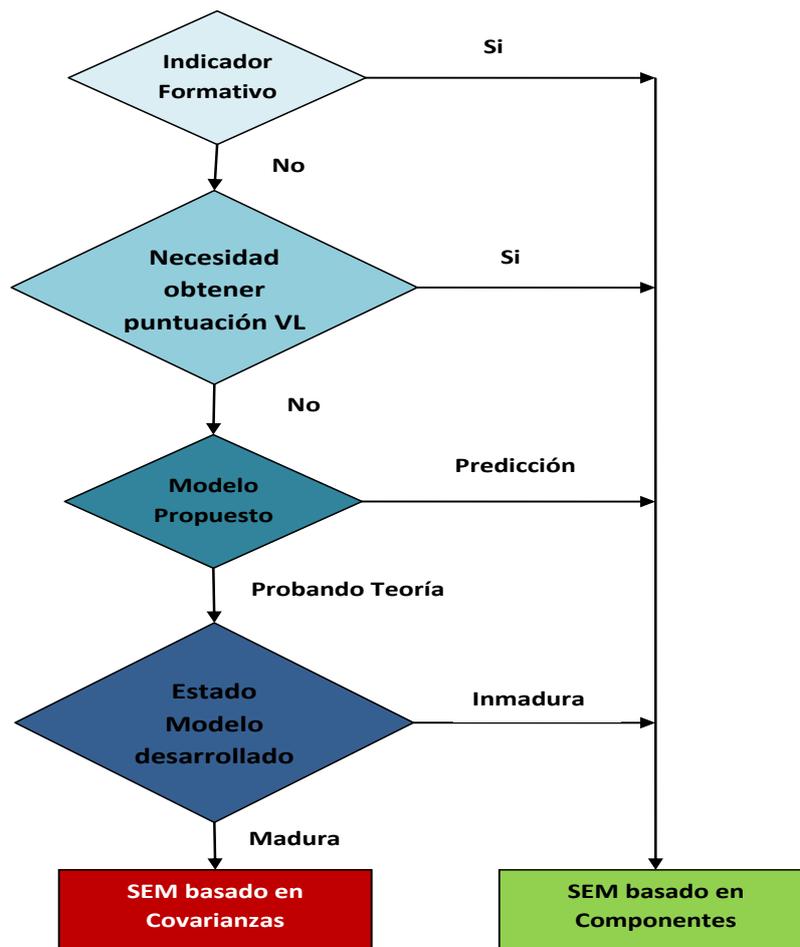
En esta sección se han mostrado las características principales de ambos enfoques, covarianzas y varianzas, así como la operación del enfoque de varianzas, por ser el que nos ocupa.

A manera de conclusión resalto que no todas las propiedades son exclusivas de un enfoque y menos aún no en todos los casos hay opiniones convergentes entre los investigadores. Los puntos en los que se ha encontrado mayor controversia sobre la robustez de los enfoques son: tamaño muestral y precisión de los estimadores. El primer punto se comentó en la sección 3.3.2.4 y, sobre la precisión de los estimadores se dice lo siguiente:

Existen estudios como el de Chin (Chin 1995 citado en Hsu S-H. *et al.* 2006, 368) donde se subraya que aún con la violación del supuesto distribucional, la estimación de los coeficientes obtenido por el enfoque de covarianzas son más precisos que los obtenidos con PLS.

Otros estudios basados en simulación, tal como Ringle, Wilson and Götz (2007, citado en Henseler *et al.* 2009, 295) concluyen que en condiciones con datos normales, el enfoque de covarianzas proporciona estimadores iguales o superiores en precisión y robustez que PLS, sin importar si el modelo de medida es formativo o reflexivo. Sin embargo cuando alguno de las premisas no se cumple, tal como la distribución de los datos o el requerimiento mínimo en las observaciones, los estimadores obtenidos con PLS son más robustos.

Es claro que la teoría de SEM está en desarrollo como la mayoría de las disciplinas, y no es extraño encontrar opiniones divergentes, sin embargo se ha encontrado que existen coincidencias sobre los elementos que determinan la elección de uno y otro enfoque. Para terminar la exposición de esta sección cito el diagrama de flujo que muestra los elementos que determinan la elección del método de estimación o enfoque (Tomado de Hsu S-H. *et al.* 2006, 369).



Fuente: Hsu, H.H. *et al.*, 2006, p. 369

Figura 20 Diagrama de Flujo de selección de técnica SEM

Finalmente subrayo la complementariedad de los enfoques para la estimación de SEM. Tal como se señaló en esta sección, cuando la teoría es madura las estimaciones con ambos métodos son similares. No hay que olvidar que la estimación con PLS posee ventajas sobre el enfoque de covarianzas sobre todo en el tamaño de la muestra, y en la estimación de modelos complejos.

4. Capítulo

Aplicación

4.1 Introducción

Toda vez que se han dado los elementos para la comprensión y análisis de los SEM, es el momento de mostrar una aplicación en la evaluación de satisfacción.

En este Capítulo se muestra la estimación del SEM desarrollado para la evaluación de la satisfacción de los beneficiarios del Programa Social Liconsa, en la modalidad de leche líquida a nivel nacional.

Las estimaciones se realizaron con el software, SmartPLS y ACSI. El modelo es evaluado bajo el enfoque de varianzas. Las características del método detalladas en el Capítulo 3, justifican la aplicación de la metodología para la estimación de modelos de satisfacción para consumidores.

El análisis de los resultados siguen los lineamientos para el análisis de SEM bajo el enfoque de varianzas, dados en el Capítulo 3. Derivado el análisis estadístico se dan conclusiones, desde la óptica estadística, de las estimaciones.

4.2 Aplicación

Los modelos estimados que se presentan en los apartados subsiguientes, corresponden a uno de los siete programas sociales evaluados en el proyecto de investigación “Diseño y Aplicación de una Metodología para el Establecimiento del Índice Mexicano de Satisfacción del Usuario de los Programas Sociales Mexicanos”, financiado por el Consejo Nacional de

Ciencia y Tecnología. Proyecto desarrollado bajo la dirección de la Dra. Odette Lobato Calleros.

En este trabajo se considera concretamente el Programa de Abasto Social de Leche Liconsa- Modalidad de leche líquida.

Para este programa se obtuvieron 1196 encuestas, de las cuales se eliminaron 50 observaciones (4.18%), por considerarse contradictorios, bajo el siguiente criterio¹⁵:

La evaluación de la Satisfacción general ≥ 9 y la evaluación de la Comparación con el ideal ≤ 4 del cual se obtuvieron 39 observaciones

o

La evaluación de la Satisfacción general ≤ 6 y la evaluación de la Comparación con el ideal ≥ 8 , del cual se obtuvieron 11 observaciones

Después de descartar los contradictorios se conservaron 1146 encuestas, con la cuales se realizó la estimación de los modelos.

El diseño del modelo, así como el cuestionario y su aplicación a nivel nacional, estuvo a cargo de los responsables del área cualitativa del equipo IMSU, encabezada por la Dra. Odette Lobato y el Mtro. Humberto Rivera. Los detalles de referentes al instrumento, diseño muestral y la aplicación de la encuesta, se pueden consultar en el Reporte del IMSU. (Lobato 2010). La Figura 4-1 se muestra el modelo utilizado para la evaluación de este programa.

¹⁵ Este criterio es propuesto y utilizado por ACSI

Como puede observarse, el modelo propuesto para la estimación posee indicadores de medida reflexivos. La escala utilizada en los cuestionarios es de tipo Likert de 1 a 10 para todas las preguntas excepto para la pregunta de quejas. La variable manifiesta quejas es dicotómica.

Las estimaciones se realizaran bajo el enfoque de varianza, debido a las características de los datos y del modelo.

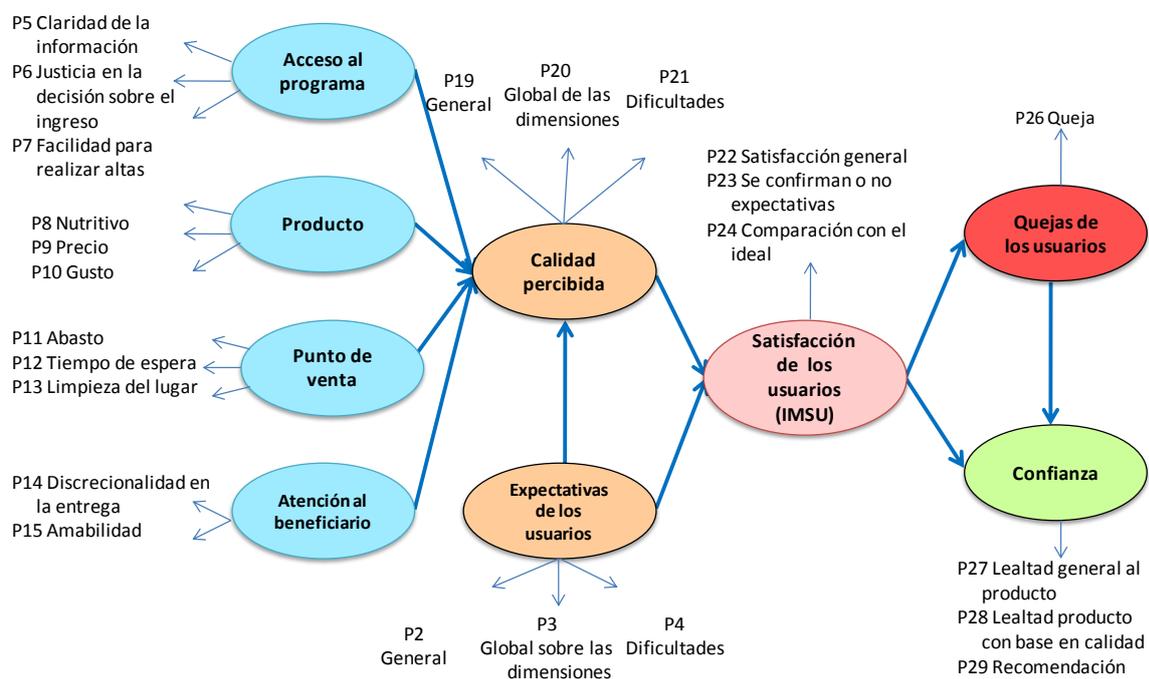


Figura 21 Modelo IMSU PAS Liconsa líquida

4.3 Análisis de Resultados

Ambos software, SmartPLS y ACSI, utilizan el método de PLS, el cual se describió con anterioridad. Sobre la estimación realizada con SmartPLS se dan los detalles de la estimación, tales como el tratamiento de valores perdidos, la opción utilizada para la estimación estructural y el cambio de signo en el re muestreo, elementos que se describieron

en el Capítulo 3 de este trabajo. Para la estimación realizada con el programa de ACSI, sólo se muestran resultados.

Se estiman dos modelos con SmartPLS considerando diferencias durante la estimación, las cuales pueden indicarse en el software. La siguiente tabla muestra las características de las estimaciones.

ESTIMACIÓN	ESTIMACIÓN DEL MODELO		BOOTSTRAPPING	
	<i>Valores perdidos</i>	<i>Estimación estructural</i>	<i>Valores perdidos</i>	<i>Cambio de signo</i>
1. SmartPLS	Case Wise Replacement	Factor Weighting Scheme	Case Wise Replacement	Individual Change
2. SmartPLS	Mean Replacement	Centroid Weighting Scheme	Mean Replacement	Construct Level Change

Como se indicó, el análisis estadístico de resultados de SEM bajo el enfoque de varianzas, se realiza considerando primero el modelo de medida y posteriormente el modelo estructural.

4.3.1 Primera estimación con SmartPLS

Para esta primera estimación se consideran sólo las entrevistas completas tanto en la estimación del modelo como en el re muestreo. Para la estimación estructural se usan las correlaciones entre las variables aleatorias. Durante el re muestreo, el signo de los pesos externos cambia de acuerdo al signo de la muestra original.

4.3.1.1 Modelo de Medida

Los resultados de la primera estimación involucran, tratamiento de valores perdidos con Case Wise Replacement y la estimación del modelo estructural con Factor Weighting Scheme.

Para evaluar la confiabilidad individual de cada indicador, se observan los pesos externos (outer weight) o correlaciones simples de los indicadores con su respectivo constructo. La regla general, a la que se hizo referencia en el Capítulo 3, es aceptar ítems con cargas estandarizadas iguales o superiores a 0.70.

Existe un criterio para eliminar indicadores con pesos estandarizados menores a 0.4, siempre que su eliminación genere mejora en la confiabilidad compuesta (Churchill 1979, citado en Henseler *et al.* 2009, 299). Este criterio parece muy tolerante, puesto que un peso de 0.70 implica una comunalidad de 0.49, que es justamente el valor mínimo para que se cumpla la validez convergente y que no puede ser cumplido por indicadores con pesos entre 0.4 a 0.69. Parece que la tolerancia del criterio de eliminación se debe a que los estimadores obtenidos con este método son consistentes cuando tanto el número de indicadores como el tamaño muestral crecen indefinidamente. De manera que es deseable conservar el mayor número de indicadores posible.

Se presentan los pesos externos para esta primera estimación.

VARIABLES MANIFIESTAS	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
Nutritivo						0.827545			
Global de las dimensiones			0.899014						
Calidad percibida último año			0.845622						
Claridad sobre la información	0.693058								
Comparación ideal									0.856076
Confirmación expectativas									0.856077
Dificultades			0.797534						
Lealtad general al producto				0.666519					
Recomendación				0.843216					
Dificultades expectativas					0.737028				
Expectativas sobre dimensiones					0.896084				
Expectativa general					0.862622				
Facilidad realizar altas	0.762597								
Lealtad producto calidad				0.635651					
Gusto						0.717169			
Justicia decisión sobre ingreso	0.808325								
Limpieza del lugar							0.703576		
Discrecionalidad entrega		0.822469							
Precio						0.604921			
Quejas								1	
Tiempo de espera							0.745719		
Satisfacción general									0.878403
Abasto							0.737196		
Amabilidad		0.824731							

Tabla 4-1 Pesos externos Modelo PAS-Liconsa Líquida. SmartPLS

Las variables latentes Acceso, Confianza y Producto tienen indicadores con pesos externos menores a 0.70, sin embargo ninguno de ellos es menor a 0.40.

Analizando el contenido de las variables latentes y considerando que el cuadrado de los pesos o correlaciones simples es la comunalidad o varianza explicada, se observa que para las variables Atención a los Beneficiarios, Calidad, Expectativas, Punto de venta y Satisfacción sus indicadores alcanzan pesos externos adecuados. El indicador de Claridad sobre la información, referente a la variable latente Acceso, está ligeramente debajo del nivel deseado. La relación del indicador con el constructo tiene una varianza compartida de 0.4803. Los indicadores Lealtad general al producto y Lealtad al producto considerando la calidad, pertenecientes al constructo de Confianza, tienen pesos menores a 0.70, siendo el segundo indicador mencionado el de menor peso, su varianza compartida es de 0.4041. Finalmente para la variable latente producto el indicador Precio del producto tienen peso externo de 0.6049, lo que se traduce en una varianza compartida de 0.3659.

Referente a la *consistencia interna* de las variables latentes hay dos alternativas para su medición, el tradicional Alfa de Cronbach y la Confiabilidad Compuesta. La recomendación dada en los artículos consultados es utilizar la segunda. El criterio para ambas mediciones es, alrededor de 0.70 en las primeras etapas de investigación y valores de entre 0.80 y 0.90 para etapas más avanzadas. Valores de 0.60 indican falta de confiabilidad (Henseler *et al.* 2009, 299).

VARIABLE LATENTE	COFIABILIDAD COMPUESTA	ALFA CRONBACH
ACCESO	0.799585	0.628342
ATEN_BENEF	0.80833	0.525768
CALIDAD	0.884896	0.804987
CONFIANZA	0.761608	0.544682
EXPECTATIVAS	0.872562	0.782534
PRODUCTO	0.763054	0.53901
PUNTO_VTA	0.772811	0.564743
QUEJAS	1	1
SATISFACCION	0.897952	0.829515

Tabla 4-2 Consistencia interna de indicadores Modelo PAS-Liconsa líquida.

La evaluación de consistencia interna a partir de la Confiabilidad Compuesta, indica que todas las variables latentes cumplen con esta característica, es decir todas las variables latentes son unidimensionales. Al comparar estos resultados con los obtenidos con el Alfa de Cronbach, se observa que los últimos están subestimados y que los constructos de Atención a los beneficiarios, Confianza, Producto y Punto de Venta muestran falta de confiabilidad.

La *validez convergente* se hace a través de la comunalidad. La media de comunalidad de cada constructo se denota por el AVE. El criterio indica que variables latentes con AVE de al menos 0.5 tienen capacidad para explicar al menos la mitad de la varianza de sus indicadores, en promedio.

VARIABLE LATENTE	AVE
ACCESO	0.571757
ATEN_BENEF	0.678318
CALIDAD	0.719788
CONFIANZA	0.519771
EXPECTATIVAS	0.696765
PRODUCTO	0.521697
PUNTO_VTA	0.531525
QUEJAS	1
SATISFACCION	0.745775

Tabla 4-3 AVE variables latentes Modelo PAS-Liconsá Líquida. SmartPLS

En la Tabla 4-3 se observa que todas las variables latentes cumplen con el criterio de validez convergente.

Como se mencionó anteriormente, en PLS hay dos criterios para evaluar la *validez discriminante*. El primero consiste en verificar que

$$\sqrt{AVE(\eta_i)} > \text{Corr}(\eta_i, \eta_j)$$

La Tabla 4-4 muestra en la diagonal la raíz cuadrada del AVE de las variables latentes y bajo la diagonal se muestran las correlaciones entre variables latentes.

VARIABLES LATENTES	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
ACCESO	0.756146								
ATEN_BENEF	0.459502	0.823601							
CALIDAD	0.436043	0.403778	0.848403						
CONFIANZA	0.323704	0.335771	0.551478	0.720951					
EXPECTATIVAS	0.368106	0.309688	0.32187	0.320235	0.834725				
PRODUCTO	0.29612	0.230688	0.350723	0.386333	0.298104	0.722286			
PUNTO_VTA	0.42686	0.469082	0.461007	0.331563	0.251194	0.38891	0.729058		
QUEJAS	0.016991	-0.064288	-0.061325	-0.041242	-0.030866	-0.076824	-0.039348	1	
SATISFACCION	0.440644	0.392024	0.73451	0.590545	0.366686	0.417525	0.437708	-0.073738	0.863583

Tabla 4-4 Raíz cuadrada del AVE vs Correlaciones Modelo PAS-Liconsa líquida.

Bajo este criterio se encuentra que el todas las variables latentes cumplen con este criterio.

Las variables latentes están más correlacionadas con sus indicadores que con el resto de las variables latentes.

El segundo criterio de validez discriminante, consiste en observar los pesos cruzados y verificar que el peso del indicador asociado a su variable latente sea mayor que el asociado a otra variable latente a la que no pertenece.

VARIABLES MANIFESTAS	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
Nutritivo	0.237689	0.170199	0.311264	0.330204	0.256812	0.827545	0.280886	-0.094125	0.384917
Global de las dimensiones	0.428481	0.395324	0.899014	0.517431	0.316499	0.350627	0.42537	-0.035922	0.703845
Calidad percibida último año	0.354344	0.312056	0.845622	0.430091	0.242579	0.267467	0.389274	-0.02336	0.600154
Claridad sobre la información	0.693058	0.377428	0.265891	0.185	0.239937	0.228834	0.317432	0.038339	0.26512
Comparación ideal	0.393821	0.367955	0.589318	0.53947	0.377271	0.326227	0.35939	-0.050896	0.856076
Confirmación expectativas	0.396412	0.34309	0.620659	0.476681	0.314755	0.38558	0.40929	-0.100806	0.856077
Dificultades	0.316601	0.312117	0.797534	0.450818	0.253632	0.26569	0.354361	-0.103701	0.552672
Lealtad general al producto	0.174791	0.232596	0.350918	0.666519	0.229994	0.281549	0.21887	0.011216	0.361827
Recomendación	0.278679	0.267808	0.517217	0.843216	0.169528	0.306594	0.278752	-0.076455	0.546989
Dificultades expectativas	0.259571	0.179073	0.208176	0.233588	0.737028	0.165755	0.168219	-0.003191	0.229708
Expectativas sobre dimensiones	0.348576	0.31052	0.309067	0.298614	0.896084	0.287635	0.228163	-0.015842	0.354837
Expectativa general	0.305224	0.266447	0.275964	0.264983	0.862622	0.273987	0.225727	-0.054289	0.316822
Facilidad realizar altas	0.762597	0.284648	0.335218	0.265526	0.226712	0.25582	0.300039	0.023085	0.329763
Lealtad producto_calidad	0.241249	0.229564	0.280899	0.635651	0.354733	0.251384	0.214491	0.001395	0.327748
Gusto	0.13453	0.174742	0.222263	0.292355	0.162636	0.717169	0.274603	-0.000323	0.261825
Justicia decisión sobre ingreso	0.808325	0.388374	0.375757	0.272844	0.35647	0.195893	0.352496	-0.014097	0.390275
Limpieza del lugar	0.362631	0.385445	0.317546	0.264766	0.158598	0.355478	0.703576	-0.023683	0.348295
Discrecionalidad entrega	0.355099	0.822469	0.331587	0.295671	0.281622	0.180126	0.350711	-0.034687	0.316499
Precio	0.271559	0.160202	0.211972	0.202258	0.21911	0.604921	0.299918	-0.059046	0.234156
Quejas	0.016991	-0.064288	-0.061325	-0.041242	-0.030866	-0.076824	-0.039348	1	-0.073738
Tiempo de espera	0.313844	0.330436	0.29286	0.228696	0.179103	0.297759	0.745719	0.007983	0.258053
Satisfacción general	0.352586	0.305461	0.691712	0.512717	0.259009	0.370793	0.366819	-0.041131	0.878403
Abasto	0.266606	0.314778	0.384285	0.232551	0.206429	0.213168	0.737196	-0.06076	0.34144
Amabilidad	0.401662	0.824731	0.333513	0.257524	0.228651	0.199808	0.421758	-0.071103	0.329208

Tabla 4-5 Pesos cruzados Modelo PAS-Liconsa líquida. SmartPLS

Al revisar los pesos cruzados se encuentra que los pesos de los indicadores asociados a su variables latente, los cuales están resaltados en la tabla, son mayores que los pesos de los indicadores asociados a cualquier otra variable latente (verificación por fila). Esto verifica la validez discriminante de los indicadores, al identificar efectivamente al constructo al que pertenece. Referente a los pesos de los indicadores sobre una variable latente (verificación por columna), también se cumple que son mayores a los de sus indicadores que el resto. En

este análisis se percibe que los pesos cruzados, de los indicadores de las variables Confianza, Calidad y Satisfacción son altos, sin superar a los propios.

4.3.1.2 Modelo Estructural

La evaluación del modelo estructural se realiza con el R^2 de las variables latentes endógenas. El criterio para este indicador, es de 0.67 se considera sustancial, de 0.33 moderado y de 0.19 pobre. Se observa principalmente la variable latente con mayor número de impactos.

Para el modelo propuesto, el R^2 de las variables manifiestas se muestra a continuación.

VARIABLES LATENTE	R2
ACCESO	
ATEN_BENEF	
CALIDAD	0.330921
CONFIANZA	0.348749
EXPECTATIVAS	
PRODUCTO	
PUNTO_VTA	
QUEJAS	0.005437
SATISFACCION	0.558436

Tabla 4-6 R^2 de las variables latentes endógena. SmartPLS

Bajo el criterio mencionado, el desempeño de la variable latente Calidad, variable con mayor número de impactos, es moderado. Hay que resaltar el R^2 de la variable latente endógena Satisfacción que alcanzó un valor de 0.558436.

La interpretación de los coeficientes de senderos, es análoga la interpretación dada a los coeficientes estandarizados de regresión. La determinación de la significancia estadística de

los coeficientes, puede hacerse con re muestreo no paramétrico. Existe la posibilidad de realizar re muestreo Jack-knife y/o Bootstrap. El software SmartPLS tiene implementado el re muestreo Bootstrap, de manera que esos son los resultados mostrados.

Para el re muestreo Bootstrap se solicitaron 500 muestras con 1000 observaciones cada una. Se considero la opción Case Wise Replacement en el tratamiento de valores perdidos, así como Individual Change en el cambio de signo en cada muestra obtenida consistente con los signos de la muestra original.

VARIABLE LATENTE	Muestra Original (O)	Media Muestra (M)	Desviación Estandar (STDEV)	Error Estandar (STERR)	Estadístico T (O/STERR)
ACCESO -> CALIDAD	0.191046	0.189863	0.048375	0.048375	3.94927
ATEN_BENEF -> CALIDAD	0.141761	0.141568	0.039211	0.039211	3.615386
CALIDAD -> SATISFACCION	0.687734	0.687195	0.036382	0.036382	18.902913
EXPECTATIVAS -> CALIDAD	0.107955	0.108573	0.038382	0.038382	2.812683
EXPEC -> SATISFACCION	0.145325	0.145963	0.033283	0.033283	4.366404
PRODUCTO -> CALIDAD	0.139145	0.142435	0.035013	0.035013	3.974152
PUNTO_VTA -> CALIDAD	0.231727	0.234589	0.050101	0.050101	4.625221
QUEJAS -> CONFIANZA	0.002316	0.028996	0.02192	0.02192	0.105673
SATISFACCION -> CONFIANZA	0.590716	0.593736	0.028897	0.028897	20.442237
SATISFACCION -> QUEJAS	-0.073738	-0.074496	0.040183	0.040183	1.835069

Tabla 4-7 Bootstrap con 2000 muestras de 1156 casos. SmartPLS

En la tabla se han resaltado los coeficientes de senderos que son estadísticamente significativos al 95% de confianza. Los coeficientes referentes a los senderos Quejas-Confianza y Satisfacción-Quejas, no son estadísticamente significativos.

Otro elemento que se muestra es la capacidad predictiva del modelo, analizada a través del procedimiento Blindfolding, y cuya rutina esta implementada en SmartPLS. Se estimó para una distancia de 7 observaciones omitidas, por ser esta la recomendación encontrada en los artículos consultados. Para valores mayores a cero resultantes de la validación cruzada de la

redundancia, obtenida con Blindfolding para variables latentes endógenas, se considera que la variable proporciona relevancia predictiva sobre sus indicadores.

VL ENDÓGENAS	CV-REDUNDANCIA
CALIDAD	0.214507
CONFIANZA	0.166269
QUEJAS	-0.00006
SATISFACCION	0.410254

Tabla 4-8 Blindfolding G=7, obtenido en SmartPLS

Para las variables latentes Calidad, Confianza y Satisfacción se considera que la variable proporciona relevancia predictiva sobre sus indicadores. Lo anterior no ocurre para la variable Quejas.

Se estimó el indicador de ajuste global para el modelo completo, GoF el cual se muestra en la Figura 4-2. Su lectura es similar a lo del R^2 . Para este caso el ajuste global es moderado.

Finalmente se muestra los resultados del modelo completo. Los coeficientes de senderos se han multiplicado por cinco, para poder comparar los resultados con los obtenidos en el software de ACSI. Las líneas continuas muestran los impactos estadísticamente significativos al 95% de confianza, mientras que las líneas punteadas muestran impactos estadísticamente no significativos.

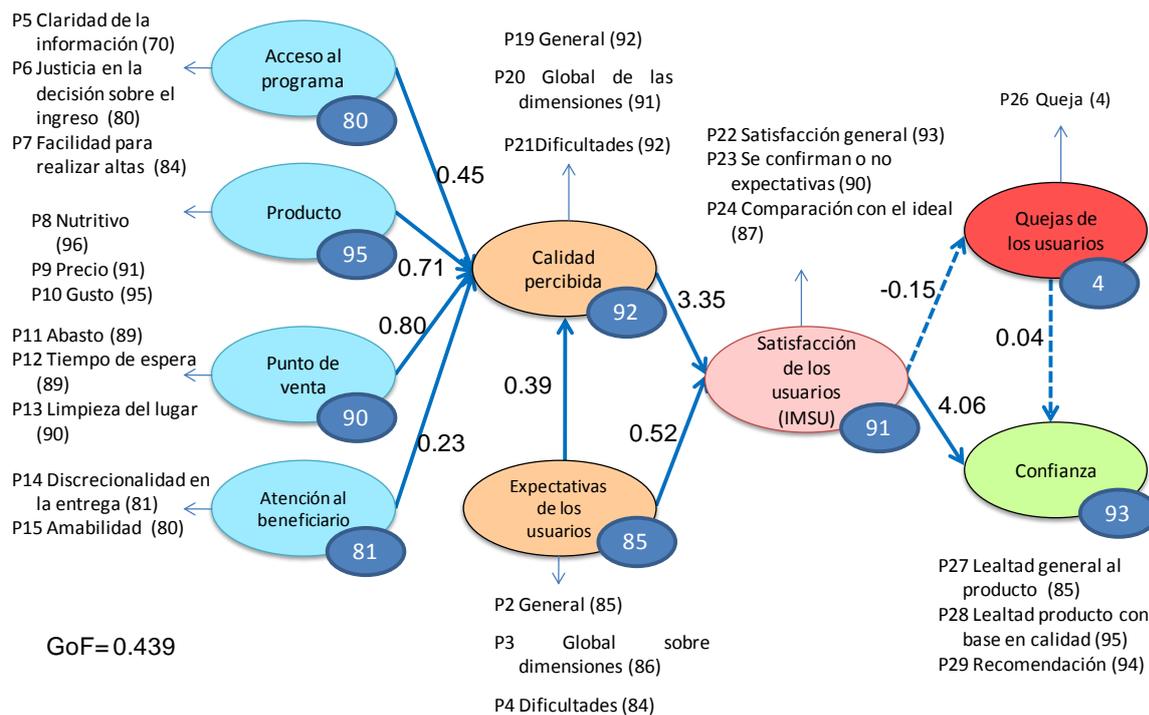


Figura 22 Modelo IMSU PAS Liconsa líquida. SmartPLS

En la estimación del modelo se observa que el orden descendente de las variables latentes que impactan a la Calidad percibida y que contemplan las características del programa son: Punto de venta, Producto, Acceso al programa y Atención al beneficiario. Los impactos estimados y señalados en línea punteada indican que son estadísticamente significativos al 95% de confianza.

El impacto de la variable latente Expectativas sobre la variable latente Calidad es estadísticamente significativo, situación poco habitual en la evaluación de programas sociales. Sobre la variable latente Satisfacción las dos variables latentes exógenas Calidad percibida y Expectativas de los usuarios impactan significativamente, siendo la Calidad la que más impacta. El impacto de la Satisfacción a Confianza es estadísticamente significativo

y de los impactos más altos del modelo. Las relaciones entre Satisfacción-Quejas y Quejas-Confianza no son estadísticamente significativas.

4.3.2 Segunda estimación con SmartPLS

A diferencia de la primera estimación aquí, en la estimación del modelo y el re muestreo los valores perdidos son reemplazados con la media. En la estimación estructural se usa el signo de las correlaciones entre las variables aleatorias. Finalmente, durante el re muestreo, el signo de los pesos externos cambia de acuerdo a la muestra original a nivel de constructo.

4.3.2.1 Modelo de Medida

Analizando la confiabilidad individual de los indicadores o variables manifiestas, se identificaron los mismos indicadores con pesos inferiores a 0.70 que en la primera estimación.

VARIABLES MANIFIESTAS	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
Nutritivo						0.819875			
Global de las dimensiones			0.8956						
Calidad percibida último año			0.844304						
Claridad sobre la información	0.680479								
Comparación ideal									0.84581
Confirmación expectativas									0.862113
Dificultades			0.800414						
Lealtad general al producto				0.64763					
Recomendación				0.852286					
Dificultades expectativas					0.737396				
Expectativas sobre dimensiones					0.895459				
Expectativa general					0.864856				
Facilidad realizar altas	0.77699								
Lealtad producto_calidad				0.63502					
Gusto						0.737238			
Justicia decisión sobre ingreso	0.807267								
Limpieza del lugar							0.738513		
Discrecionalidad entrega		0.824122							
Precio						0.620532			
Quejas								1	
Tiempo de espera							0.741622		
Satisfacción general									0.870839
Abasto							0.721671		
Amabilidad		0.824479							

Tabla 4-9 Pesos externos Modelo PAS-Liconsa Líquida. SmartPLS

Se muestra las dos alternativas para verificar la *consistencia interna* de las variables latentes, Alfa de Cronbach y la Confiabilidad Compuesta.

VARIABLE LATENTE	CONFIABILIDAD COMPUESTA	ALFA CRONBACH
ACCESO	0.800088	0.630489
ATEN_BENEF	0.809149	0.528267
CALIDAD	0.884292	0.803651
CONFIANZA	0.758535	0.543068
EXPECTATIVAS	0.873138	0.784205
PRODUCTO	0.772164	0.559378
PUNTO_VTA	0.777945	0.575287
QUEJAS	1	1
SATISFACCION	0.894658	0.823319

Tabla 4-10 Consistencia interna de los indicadores Modelo PAS-Liconsa Líquida.

La interpretación de los resultados obtenidos en esta estimación, coincide con los obtenidos en la primera estimación.

La verificación de la *validez convergente* con el AVE, se muestra en la siguiente tabla.

VARIABLE LATENTE	AVE
ACCESO	0.572815
ATEN_BENEF	0.679471
CALIDAD	0.718537
CONFIANZA	0.516355
EXPECTATIVAS	0.697858
PRODUCTO	0.533592
PUNTO_VTA	0.538738
QUEJAS	1
SATISFACCION	0.738998

Tabla 4-11 AVE variables latentes Modelo PAS-Liconsa líquida. SmartPLS

Todas las variables latentes cumplen con el criterio. Numéricamente, las diferencias entre la primera estimación y esta se dan en el tercer decimal, salvo en las variables Producto y Satisfacción.

Se muestran los dos criterios para evaluar la *validez discriminante*.

VARIABLES LATENTES	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
ACCESO	0.756845								
ATEN_BENEF	0.464668	0.824300							
CALIDAD	0.447671	0.413418	0.847666						
CONFIANZA	0.341308	0.339532	0.557611	0.718578					
EXPECTATIVAS	0.348577	0.279225	0.311497	0.318024	0.835379				
PRODUCTO	0.28293	0.197684	0.334548	0.382472	0.297993	0.730474			
PUNTO_VTA	0.437223	0.486788	0.47088	0.345468	0.228427	0.380287	0.733988		
QUEJAS	-0.014066	-0.080119	-0.07915	-0.059639	-0.020519	-0.067906	-0.075005	1	
SATISFACCION	0.444414	0.39905	0.725207	0.580008	0.355087	0.389379	0.434463	-0.071527	0.859650

Tabla 4-12 Ráiz cuadrada del AVE vs Correlaciones Modelo PAS-Liconsá líquida.

Bajo las opciones de esta estimación, también se identifican que todas la variables latentes cumplen con el criterio, tal como ocurrió en la primera estimación.

VARIABLES MANIFIESTAS	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
Nutritivo	0.235371	0.138406	0.289746	0.323961	0.251361	0.819875	0.281166	-0.08919	0.354653
Global de las dimensiones	0.427796	0.39866	0.8956	0.509035	0.298312	0.325677	0.432172	-0.05267	0.689588
Calidad percibida último año	0.356479	0.312096	0.844304	0.429316	0.238494	0.271877	0.392453	-0.02586	0.598084
Claridad sobre la información	0.680479	0.378894	0.26169	0.196962	0.221032	0.212485	0.322049	0.010656	0.26737
Comparación ideal	0.390931	0.360154	0.570735	0.5227	0.365484	0.314522	0.349386	-0.0366	0.84581
Confirmación expectativas	0.396724	0.347889	0.617668	0.476265	0.302679	0.35103	0.404887	-0.10403	0.862113
Dificultades	0.347596	0.334303	0.800414	0.477439	0.250963	0.246746	0.369361	-0.12815	0.545955
Lealtad general al producto	0.189163	0.236889	0.359117	0.64763	0.22428	0.272985	0.231972	0.004905	0.363429
Recomendación	0.290604	0.268552	0.507894	0.852286	0.178959	0.302092	0.28768	-0.09143	0.519196
Dificultades expectativas	0.246129	0.162197	0.201627	0.232227	0.737396	0.158419	0.165504	-0.00196	0.213713
Expectativas sobre dimensiones	0.331976	0.278927	0.301622	0.305177	0.895459	0.301976	0.202976	-0.0063	0.343562
Expectativa general	0.287148	0.240641	0.264237	0.253889	0.864856	0.262569	0.201424	-0.04071	0.313117
Facilidad realizar altas	0.77699	0.301307	0.360306	0.286562	0.221143	0.233716	0.32055	-0.00229	0.337225
Lealtad producto_calidad	0.25	0.234592	0.299016	0.63502	0.344296	0.258694	0.222744	-0.01155	0.33734
Gusto	0.13376	0.159573	0.227447	0.290347	0.182779	0.737238	0.275217	0.004063	0.25176
Justicia decisión sobre ingreso	0.807267	0.388603	0.379175	0.279577	0.339778	0.201435	0.354242	-0.03352	0.390624
Limpieza del lugar	0.376816	0.389703	0.349563	0.277243	0.146625	0.337173	0.738513	-0.0581	0.353455
Discrecionalidad entrega	0.36272	0.824122	0.340624	0.303332	0.260302	0.156884	0.372339	-0.04443	0.332891
Precio	0.253001	0.140598	0.207053	0.21361	0.215605	0.620532	0.284484	-0.05469	0.230851
Quejas	-0.014066	-0.080119	-0.07915	-0.059639	-0.020519	-0.067906	-0.075005	1	-0.071527
Tiempo de espera	0.306183	0.343327	0.298514	0.227651	0.171719	0.287473	0.741622	0.003199	0.258363
Satisfacción general	0.35782	0.320522	0.682661	0.49667	0.246424	0.3385	0.365777	-0.04335	0.870839
Abasto	0.279954	0.337342	0.378168	0.251419	0.183425	0.218079	0.721671	-0.09806	0.333803
Amabilidad	0.403314	0.824479	0.340937	0.256442	0.200056	0.169013	0.430154	-0.08764	0.324986

Tabla 4-13 Pesos cruzados Modelo PAS-Liconsá Líquida. SmartPLS

Se observan las mismas conclusiones que en la primera estimación. Todas las variables cumplen con el segundo criterio de validez discriminante.

4.3.2.2 Modelo Estructural

Se muestra el R² obtenido en esta segunda estimación.

VARIABLE LATENTE	R2
ACCESO	
ATEN_BENEF	
CALIDAD	0.33938
CONFIANZA	0.336741
EXPECTATIVAS	
PRODUCTO	
PUNTO_VTA	
QUEJAS	0.005116
SATISFACCION	0.544407

Tabla 4-14 R² de las variables latentes endógenas. SmartPLS

Los resultados en esta estimación difieren poco de las obtenidas anteriormente.

RELACIONES ENTRE VL	Muestra Original (O)	Media Muestra (M)	Desviación Estandar (STDEV)	Error Estandar (STERR)	Estadístico T (O/STERR)
ACCESO -> CALIDAD	0.201198	0.197258	0.046448	0.046448	4.331651
ATENCION -> CALIDAD	0.149155	0.147298	0.038438	0.038438	3.880408
CALIDAD -> SATISFACCION	0.680641	0.679855	0.035001	0.035001	19.44655
EXPECTATIVAS -> CALIDAD	0.107975	0.1101	0.037733	0.037733	2.861586
EXPECTATIVAS -> SATISFACCION	0.14307	0.144486	0.030613	0.030613	4.673523
PRODUCTO -> CALIDAD	0.125484	0.12899	0.035024	0.035024	3.582768
PTO_VENTA -> CALIDAD	0.23792	0.241192	0.049501	0.049501	4.806403
QUEJAS -> CONFIANZA	-0.018246	-0.032864	0.024774	0.024774	0.736524
SATISFACCION -> CONFIANZA	0.578703	0.579355	0.029094	0.029094	19.890967
SATISFACCION -> QUEJAS	-0.071527	-0.074211	0.040067	0.040067	1.785188

Tabla 4-15 Bootstrap con 2000 muestras de 1146 casos. SmartPLS

En general el estadístico *t* en esta estimación es más alto que el obtenido en la primera estimación, sin embargo los dos coeficientes de senderos que no resultaron significativos al 95% de confianza en la primera estimación, continúan sin serlo en esta estimación.

A continuación se muestran la validación cruzada de la redundancia en el Blindfolding.

VL ENDÓGENAS	CV-REDUNDANCIA
CALIDAD	0.22293
CONFIANZA	0.163846
QUEJAS	-0.000733
SATISFACCION	0.397803

Tabla 4-16 Blindfolding G=7, obtenido en SmartPLS

Los resultados muestran el mismo comportamiento que el obtenido en la primera estimación.

Sólo la variable latente Quejas no muestra capacidad predictiva sobre sus indicadores.

Se estimó el indicador de ajuste global para el modelo completo, GoF, cuya lectura muestra un ajuste moderado.

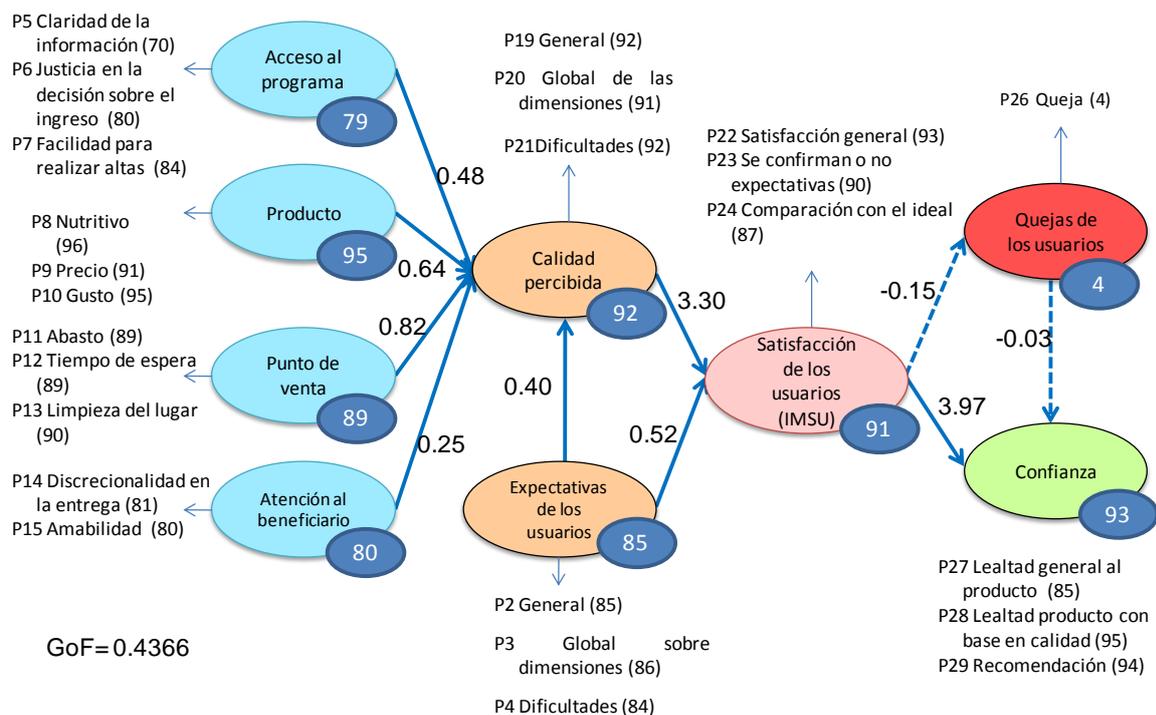


Figura 23 Modelo IMSU PAS Liconsa líquida, SmartPLS

En la estimación del modelo se observa que el orden descendente de los coeficientes de senderos de las variables latentes que impactan a la Calidad percibida y que consideran las características del programa son: Punto de venta, Producto, Acceso al programa y Atención al beneficiario, todos estadísticamente significativos.

Tal como ocurrió en la primera estimación, el impacto de Expectativas a Calidad es estadísticamente significativo. Sobre la variable latente Satisfacción las dos variables latentes exógenas Calidad percibida y Expectativas de los usuarios impactan significativamente, siendo la Calidad la que más impacta. El impacto de la Satisfacción a Confianza es estadísticamente significativo y de los impactos más altos del modelo. Las relaciones entre Satisfacción-Quejas y Quejas-Confianza no son estadísticamente significativas. El signo de la última relación mencionada, a diferencia de la primera estimación, tiene signo positivo.

4.3.3 Estimación con ACSI

En esta sección se muestran los resultados obtenidos en la estimación con el software diseñado por ACSI. En el Capítulo 3 se señaló que la normalización de las variables latentes propuesta por Fornell 1992, difiere de la propuesta por Wold 1985 donde las variables latentes tienen desviación estándar igual a uno, sin embargo ambas son colineales.

Según Tenenhaus, (Tenenhaus 2005, 178) la metodología de Fornell realiza la estimación interna de las estimación con Centroid Scheme.

Todos los elementos que se presentan provienen de los resultados arrojados por el programa.

4.3.3.1 Modelo de Medida

Comenzamos revisando la confiabilidad individual de los indicadores o variables manifiestas.

VARIABLES LATENTES	ACCESO	ATEN_BENEF	CALIDAD	CONFIANZA	EXPECTATIVAS	PRODUCTO	PUNTO_VTA	QUEJAS	SATISFACCION
Nutritivo						0.8208			
Global de las dimensiones			0.8955						
Calidad percibida último año			0.8465						
Claridad sobre la información	0.6812								
Comparación ideal									0.8503
Confirmación expectativas									0.8608
Dificultades			0.7984						
Lealtad general al producto				0.6767					
Recomendación				0.8256					
Dificultades expectativas					0.737				
Expectativas sobre dimensiones					0.8961				
Expectativa general					0.8681				
Facilidad realizar altas	0.7795								
Lealtad producto_calidad				0.6486					
Gusto						0.7377			
Justicia decisión sobre ingreso	0.8105								
Limpieza del lugar							0.7383		
Discrecionalidad entrega		0.8281							
Precio						0.6187			
Quejas								1	
Tiempo de espera							0.7415		
Satisfacción general									0.8803
Abasto							0.7223		
Amabilidad		0.8248							

Tabla 4-17 Pesos externos estimados con ACSI

Los resultados numéricos son un poco diferentes a los obtenidos en SmartPLS. El comportamiento y análisis es idéntico.

La siguiente tabla muestra el Alfa de Cronbach obtenida en ACSI, con lo que se analiza la *consistencia interna* de las variables latentes.

VARIABLES LATENTE	ALFA CRONBACH
ACCESO	0.6357
ATEN_BENEF	0.5359
CALIDAD	0.8037
CONFIANZA	0.5432
EXPECTATIVAS	0.7864
PRODUCTO	0.5594
PUNTO_VTA	0.5756
QUEJAS	-
SATISFACCION	0.83

Tabla 4-18 Alfa de Cronbach estimado con ACSI

Al igual que en la estimación con SmartPLS el Alfa de Cronbach para las variables Atención a los beneficiarios, Confianza, Producto y Punto de Venta muestran falta de confiabilidad.

Como se describió en el Capítulo 3, otra herramienta para verificar la consistencia interna de las variables latentes, es el análisis de Componentes Principales. A continuación se muestra este análisis.

VARIABLES LATENTES	VALORES PROPIOS		
ACCESO	1.7362	0.6707	0.593
ATEN_BENEF	1.3661	0.6339	
CALIDAD	2.1569	0.5145	0.3286
CONFIANZA	1.5694	0.7696	0.661
EXPECTATIVAS	2.1062	0.5579	0.3358
PRODUCTO	1.6039	0.815	0.581
PUNTO VTA	1.6304	0.8007	0.5689
QUEJAS	-	-	-
SATISFACCIÓN	2.239	0.4174	0.3435

Tabla 4-19 Valores propios de las variables latentes

Para todas las variables latentes se cumple que el primer valor propio es superior a uno y el segundo es menor a uno, lo cual indica que las variables son unidimensionales y por tanto son consistentes internamente.

Se analiza el AVE de las variables latentes para verificar la *validez convergente*.

VARIABLES LATENTE	AVE*
ACCESO	0.571757
ATEN_BENEF	0.678318
CALIDAD	0.719788
CONFIANZA	0.519771
EXPECTATIVAS	0.696765
PRODUCTO	0.521697
PUNTO_VTA	0.531524
QUEJAS	1
SATISFACCION	0.745775

Tabla 4-20 Comunalidad de las variables latentes estimada con ACSI

Se observa que todas las variables latentes cumplen con el criterio de validez convergente.

A continuación se muestran el primer criterio para verificar la *validez discriminante*.

VARIABLES LATENTES	ACCESO	PRODUCTO	PUNTO_VTA	ATEN_BENEF	EXPECTATIVAS	CALIDAD	SATISFACCIÓN	QUEJAS	CONFIANZA
ACCESO	0.7561								
PRODUCTO	0.2753	0.7223							
PUNTO_VTA	0.4225	0.3797	0.7291						
ATEN_BENEF	0.4523	0.1927	0.4781	0.8236					
EXPECTATIVAS	0.3527	0.3017	0.2262	0.2684	0.8347				
CALIDAD	0.3466	0.3358	0.4710	0.4047	0.3109	0.8484			
SATISFACCIÓN					0.3485	0.7349	0.8636		
QUEJAS							-0.07596	1	
CONFIANZA							0.5817	-0.0550	0.720951455

Tabla 4-21 Ráiz cuadrada del AVE vs Correlaciones Modelo PAS-Liconsalíquida

Nuevamente hay pequeñas diferencias numéricas. En todos los casos se cumple con el criterio de validez discriminante.

4.3.3.2 Modelo Estructural

Para el modelo propuesto, el R^2 de las variables manifiestas se muestra a continuación.

VARIABLES LATENTE	R2	R2 AJUSTADA
ACCESO		
ATEN_BENEF		
CALIDAD	0.3356	0.3327
CONFIANZA	0.3385	0.3373
EXPECTATIVAS		
PRODUCTO		
PUNTO_VTA		
QUEJAS	0.0058	0.0049
SATISFACCION	0.5555	0.5547

Tabla 4-22 de las variables latentes endógenas estimado con ACSI

Las R^2 de las variables latentes obtenidas con ACSI son muy parecidas a las generadas en SmartPLS.

La siguiente Tabla muestra los intervalos de confianza para los coeficientes de senderos en donde se aprecia aquellos que son estadísticamente significativos al 90% y 95% de confianza.

RELACIONES ENTRE VL	Coeficiente	Intervalo al 90%	Intervalo al 95%
ACCESO -> CALIDAD	0.19058	0.04787	0.05704
ATEN_BENEF -> CALIDAD	0.14618	0.04801	0.05721
CALIDAD -> SATISFACCION	0.69421	0.03415	0.04068
EXPECTATIVAS -> CALIDAD	0.10988	0.04392	0.05233
EXPECTA -> SATISFACCION	0.1308	0.03415	0.04068
PRODUCTO -> CALIDAD	0.12815	0.04444	0.05294
PUNTO_VTA -> CALIDAD	0.24707	0.04909	0.05849
QUEJAS -> CONFIANZA	-0.01084	0.03981	0.04743
SATISFACCION -> CONFIANZA	0.58087	0.03981	0.04743
SATISFACCION -> QUEJAS	-0.07596	0.04862	0.05793

Tabla 4-23 Coeficientes de senderos estandarizados estimados en ACSI

El único coeficiente de sendero que no es estadísticamente significativo es el se obtiene de la relación Quejas-Confianza. El impacto Satisfacción-Quejas es significativo, sin embargo está muy cerca de no serlo. En la estimación con SmartPLS esta relación no es significativa y está muy cerca de serlo.

Si se comparan los coeficientes estandarizados obtenidos en las estimaciones con ambos software (ej. Tabla 4-16 vs Tabla 4-24) se concluye que la magnitud de los impactos es muy similar y que además en orden descendente tienen el mismo comportamiento.

Se estimó el indicador de ajuste global para el modelo completo, GoF. Para este caso la bondad de ajuste es moderada.

Finalmente se muestra los resultados del modelo completo. Los coeficientes de senderos resultantes con el software de ACSI están multiplicados por cinco. Las líneas continuas muestran los impactos estadísticamente significativos al 95% de confianza, mientras que los líneas punteadas muestran impactos estadísticamente no significativos.

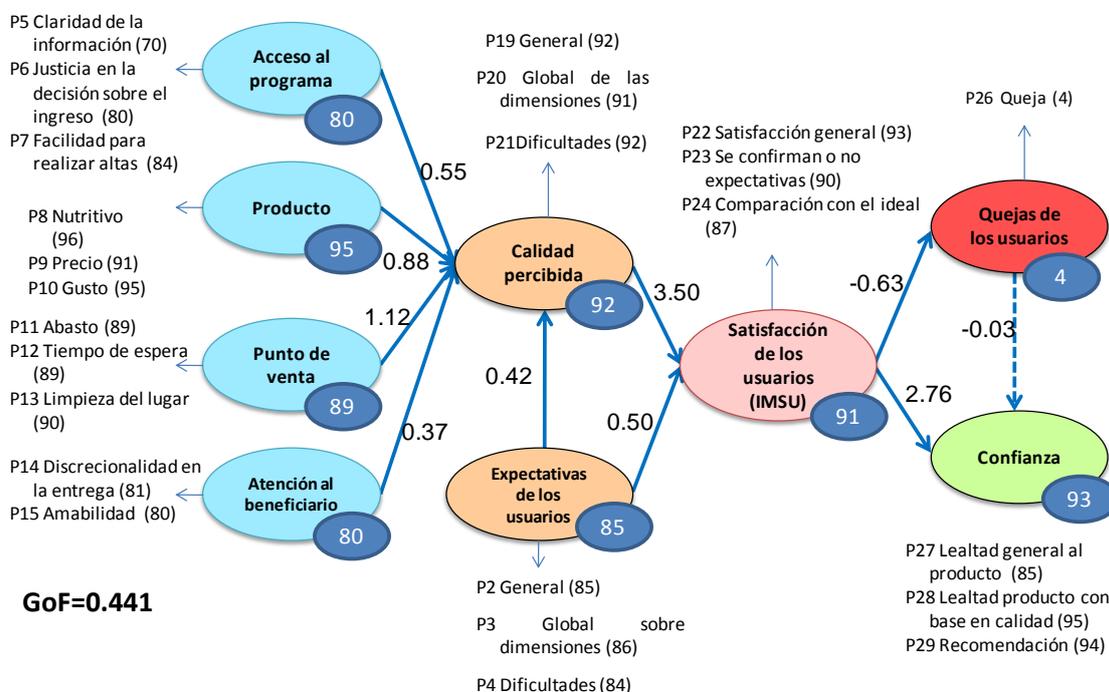


Figura 24 Modelo IMSU PAS Licónsa Líquida, ACSI

En la estimación del modelo se observan que el orden descendente de los coeficientes de senderos de las variables latentes que impactan a la Calidad percibida y que consideran las características del programa, son: Punto de venta, Producto, Acceso al programa y Atención al beneficiario. Todos ellos significativos al tiene al 95% de confianza.

Tal como se ha venido observando el impacto de Expectativas a Satisfacción es significativo. Sobre la variable latente Satisfacción las dos variables latentes exógenas Calidad percibida y Expectativas de los usuarios impactan significativamente, siendo la Calidad la que más impacta. Las relaciones Satisfacción-Confianza y Satisfacción-Quejas son estadísticamente significativas, mientras que Quejas-Confianza no lo es.

La satisfacción general de los beneficiarios con el programa está evaluada en 90.6 con un margen de error de ± 0.72 .

4.4 Conclusiones

Los análisis de confiabilidad individual de los indicadores, consistencia interna del constructo, validez convergente y validez discriminante, en las tres estimaciones tienen el mismo comportamiento. Se observa en las tres estimaciones valores externos semejantes, y más semejantes aún son los valores obtenidos en ACSI y los resultantes de en la segunda estimación con SmartPLS, que considera el reemplazo de los valores perdidos por la media y la estimación interna bajo la opción de Centroid Sheme.

Sobre la variable latente Confianza, en el análisis de los pesos externos se observó que dos de sus indicadores (Lealtad general al producto y Lealtad producto con base en calidad) tienen pesos inferiores al deseable 0.70. Se recomienda revisar la formulación de los dos

indicadores mencionados, si se ratifica que esas intenciones de comportamiento son relevantes para el Programa. Si se considera que existen otras intenciones tanto o más importantes, se podrían sustituir los reactivos actuales. Por otro lado hay que considerar la posibilidad de eliminar el reactivo sobre Lealtad producto con base en calidad, el cual tiene el menor peso externo.

En las tablas de coeficientes de senderos estandarizados, en las tres estimaciones, los resultados son muy similares y el comportamiento en el orden de los impactos idéntico, situación que prevalece en los resultados des-estandarizados. Llama la atención que en las estimaciones con SmartPLS el impacto entre calidad y Satisfacción es menor que el impacto entre Satisfacción y Confianza, mientras que en la estimación en ACSI el comportamiento es justamente a la inversa. Sobre esta diferencia no se tiene elementos que puedan explicarlo.

La segunda estimación en SmartPLS, se aproxima más a las características metodológicas de ACSI, según los elementos encontrados en los artículos revisados. Se presume que en la estimación de ACSI, el tratamiento de valores perdidos se hace remplazando a la media. Según Cordeiro (Cordiero, *et al*, 2010, p. 286), para estimaciones estándar de Modelos de Satisfacción de Consumidor con PLS, el reemplazamiento de los valores perdidos por la media, es un procedimiento *ad hoc* adoptado por ECSI. En los resultados mostrados, con las variantes de tratamiento de valores perdidos, no se aprecian grandes diferencias en la evaluación del modelo, esto puede deberse al tamaño de la muestra.

Referente a las significancia estadística de los coeficientes de medida, se observa que la relación Satisfacción-Quejas esta en el límite del valor crítico, en las tres estimaciones.

Los indicadores de ajuste parcial R^2 y global GoF , muestra un ajuste moderado del modelo.

En las tres estimaciones los resultados son similares.

CONCLUSIONES Y RECOMENDACIONES

Al parecer debido a las características de los datos de estudios de satisfacción, así como a la madurez de la propia investigación y el tamaño de muestra, resulta el enfoque de varianzas un método robusto. También se concluye, de la revisión bibliográfica y del análisis realizado en este caso, que para estudios de este tipo es deseable que el tratamiento de los valores perdido sea: *mean replacement*. El esquema para la estimación estructural *Centroid Weighting Scheme* considera el signo de la correlaciones, lo cual contribuye a la obtención de resultados coherentes, sin embargo *Path Centroid Weighting Scheme* se recomienda en mayor medida por considerar las elementos de las relaciones propuestas.

Por lo que se refiere a los resultados del modelo propuesto y analizado, se han obtenido indicadores aceptables, para esta etapa de investigación. De seguir trabajando en la construcción y particularización de estos modelos es posible obtener indicadores con mejor desempeño.

En la comparación entre los resultados de los análisis estadísticos realizados, provenientes de los software utilizados, desde el punto de vista de la investigación y por los resultados mostrados, es preferible la estimación realizada con SmartPLS, por que se elige el tipo de procedimiento deseado.

Indiscutiblemente hay elementos que bien valdría que fueran revisados. Como se indicó la teoría determina las relaciones causales del modelo. En la mayoría de los estudios que se han realizado bajo este proyecto, se obtuvieron impactos no significativos entre las expectativas y la calidad percibida, por lo que se recomienda revisar los indicadores de esta variable latente, y/o estudiar su sustitución por otra variable, tal como la Imagen. Otro espacio de exploración que se tiene es la incorporación de las características demográficas de los clientes en el modelo, tal como lo muestra el modelo de Hong Kong. Igualmente es un área de oportunidad la mejora e incorporación de indicadores que reflejen a la variable latente quejas y más aún en un contexto en donde los usuarios y/o clientes no tienen la cultura del establecimiento formal de las quejas.

El análisis realizado identifica indicadores que con desempeño pobre, es deseable que se consideren en próximas aplicaciones.

Se mencionó de manera superficial, la existencia de propuestas estadísticas en donde se mezclan procedimientos de ambos enfoques, generando un método más robusto, que además considera relaciones no lineales. Tienen sentido considerar esos avances en próximas investigaciones.

5. Bibliografía

Bayol M., Foye A., Tellier C., Tenenhaus M. 2000. Use of PLS Path Modelling to estimate the European Consumer Satisfaction Index (ECSI) model. *Statistica Applicata* 12(3): 316-375.

Chatelin Y. M., Esposito V. V., Tenenhaus M. 2002. State-of-art on PLS Path Modeling through the available software. Descargado de www.hec.fr/var/fre/storage/original/application/d713bfa13eff075210485ada1a2f7c48.pdf

Chin W. W. 2010. How to Write Up and Report PLS Analyses. En *Handbook of Partial Least Squares*, editado por V. Esposito, W. Chin, J. Henseler and H. Wang 655-690, Heidelberg: Springer.

Cordeiro C., Machás A., Neves M. M. 2010. A Case Study of a Customer Satisfaction Problem: Bootstrap and Imputation Techniques. En *Handbook of Partial Least Squares*, editado por V. Esposito, W. Chin, J. Henseler and H. Wang 279-287, Heidelberg: Springer.

Cortázar V. 2007. Entre el diseño y la evaluación: El papel crucial de la implementación de los programas sociales. Banco Interamericano de Desarrollo, USA.

Diamantopoulos A., Winklhofer H. M. 2001. Index Construction with Formative Indicators: An Alternative to Scale Development. *Journal of Marketing* XXXVIII:269-277

Esposito V., Trinchera L., Amato S. 2010. PLS Path Modeling: From Foundation to Recent Developments and Open Issues form Model Assessment and Improvement. En *Handbook of Partial Least Squares*, editado por V. Esposito, W. Chin, J. Henseler and H. Wang 47-82, Heidelberg: Springer.

Fernandez V. 2004. Tesis doctoral Relaciones encontradas entre las dimensiones de las estructuras organizacionales y los componentes del constructo capacidad de absorción: El caso de empresas ubicadas en el territorio español. Barcelona.

Fornell C., Bookstein F. L. 1982. Two Structural Equation Models: LISREL and PLS Applied to Consumer Exit-Voice Theory. *Journal of Marketind Research* 19(4): 440-452.

Fornell C., Johnson M. D., Anderson E. W., Jaesung C., Bryand B. E. 1996. The American Customer Satisfaction Index: Purpose, and Findings. *Journal of Marketing* 60(4):7-18.

Fornell C., Larcker D. 1981. Structural Equation Models With Unobserved Variables and Measurement Error: Algebra and Statistics. *Journal of Marketing Research* 18 (3): 382-388.

Haenlein, M. & Kaplan, A. M. 2004. A beginner's guide to Partial Least Squares Analysis. *Understanding Statistics* 3(4): 283-297.

Henseler J. 2011. Curso PLS *Path Modeling with SmartPLS Foundations, Applications, Extensions*. Universidad Iberoamericana Ciudad de México.

Henseler, J., Ringle, C. M. & Sinkovics, R. R. 2009. The use of Partial Least Squares Path Modeling in international marketing. *Advances in International Marketing*, 20:277-319.

Hsu, S.-H., Chen, W.-H., & Hsieh, M.-J. 2006. Robustness testing of PLS, LISREL, EQS and ANN-based SEM for measuring customer satisfaction. *Total Quality Management & Business Excellence* 17(3): 355-371.

Huerta de la Fuente. 2011. Uso de la metodología cualitativa en la evaluación de la satisfacción y confianza en los usuarios de un programa de política social. Estudio de caso tiendas Diconsa en Tlaxcala. Universidad Iberoamericana.

Johnson D., Fornell C., 1991. A framework for comparing customer satisfaction across individuals and product categories. *Journal of Economic Psychology* 12:267-286.

Jöreskog K.G. 1993. LISREL 8. Structural equation modelling with SIMPLIS command language. Chicago, III: 226.

Juárez S., Hernández R., Montero J., Velasco M., Zamudio R., Juárez A., Hernández O., Zavala O., Lara J., Delfino C., Cruz C., Rodríguez A. 2008. Estudio de medición de la percepción de los beneficiarios de la modalidad de abasto rural del programa de abasto alimentario y abasto rural a cargo de DICONSA S.A. de C.V. Universidad Veracruzana, México, 464. Descargado de http://www.sedesol.gob.mx/archivos/802363/file/diconsa/2_Resumen_Ejecutivo.pdf

Lai K. Chan, Yer V. Hui, Hing P. Lo, Siu K. Tse, Geoffrey K.F. Tso and Ming L. Wu. 2008. Consumer satisfaction index: new practice and findings. *European Journal of Marketing* 37 (5&6):872-909.

Lévy J. P., González N., Muñoz M. 2006. Modelos Estructurales según el Método de Optimización de Mínimos Cuadrados Parciales (PLS). En *Modelización con estructuras de covarianzas en ciencias sociales: temas esenciales, avanzados y aportaciones especiales*, editado por Lévy J., González N. A., Muñoz M. D. 321-353, Netbiblo.

Lobato O., Serrato H., Rivera H. 2006. Versión Final del Reporte de la Aplicación de la Metodología para la Obtención del Índice de Satisfacción del Beneficiario del Programa de Desarrollo Local. México D.F.

Lobato O., Serrato H., Rivera H., Gómez M., León C., Cervantes P. 2011. Reporte Prueba Piloto del IMSU-Programas Sociales Mexicanos. Programa de Abasto Social de Leche Liconsa – Modalidad de leche líquida. México D.F.

Manly, Bryan F. 1986. *Multivariate Statistical Methods*. Nueva Zelanda, 159.

Manzano P. 2003. Movilización del plomo en hueso durante el embarazo. Una aplicación de los modelos de ecuaciones estructurales. México, UNAM-IIMAS.

Marshall P., Díaz M., & Rodrigo C. 2003. Satisfacción del consumidor en Chile: una aplicación de la metodología de índices nacionales de satisfacción. *Estudios de Administración* 10(1): 49-75. Academic Search Complete, EBSCO host (consultado May 19, 2009).

Morgeson, F. (s/f). How much is enough? Sample size, Sampling and the CFI Group Method. CFI Group internal document.
Ringle C.M., Wende S., Will A., 2005, SmartPLS 2.0 (M3), Hamburg.
<http://www.smartpls.de>

Romney M., Jenkins C., Bynner H. 1992. A Structural Analysis of Health-Related Quality of Life Dimensions. *Human Relations* 45(2).

Tenenhaus, M. (2008). Component-based Structural Equation Modelling. *Total Quality Management & Business Excellence*, 19(7&8): 871-886.

Tenenhaus, M., Esposito Vinzi, V., Chatelin, Y-M. & Lauro, C. (2005). PLS path modeling. *Computational Statistics & Data Analysis*, 48(1): 159-205.
The ACSI technical staff. 2005. *American Customer Satisfaction Index. Methodology Report*. National Quality Research Center, Stephen M. Ross School of Business, University of Michigan.