

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

ESCUELA DE POSGRADO

MAESTRÍA EN ESTADÍSTICA APLICADA



**“MODELO DE ECUACIÓN ESTRUCTURAL EXPLICATIVO DEL
RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES DEL CURSO
DE ESTADÍSTICA GENERAL EN LA UNALM”**

Presentada por:

ROLANDO JESÚS SALAZAR VEGA

**TESIS PARA OPTAR EL GRADO DE
MAGISTER SCIENTIAE EN ESTADÍSTICA APLICADA**

Lima-Perú

2019

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

ESCUELA DE POSGRADO

MAESTRÍA EN ESTADÍSTICA APLICADA

**“MODELO DE ECUACIÓN ESTRUCTURAL EXPLICATIVO DEL
RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES DEL CURSO
DE ESTADÍSTICA GENERAL EN LA UNALM”**

**TESIS PARA OPTAR EL GRADO DE
MAGISTER SCIENTIAE EN ESTADÍSTICA APLICADA**

Presentada por:

ROLANDO JESÚS SALAZAR VEGA

Sustentada y aprobada ante el siguiente jurado:

Mg.Sc. Clodomiro Miranda Villagomez
PRESIDENTE

M.A. Fernando Rosas Villena
ASESOR

Mg. Jesús Salinas Flores
MIEMBRO

MS. Carlos López de Castilla Vásquez
MIEMBRO

DEDICATORIA

A mi madre, mi padre (que en paz descanse) y mi hermano; por el apoyo y las ayudas recibidas durante estos años en mi vida personal, profesional y académica.

AGRADECIMIENTOS

En primer lugar a Dios, que quiere lo mejor para nosotros.

A mi familia por el apoyo y las ayudas recibidas.

Al profesor M.A. Fernando Rosas Villena por su apoyo, orientación y paciencia en el desarrollo de este trabajo.

A mis amistades y a todas aquellas personas que ayudaron de alguna u otra forma en el desarrollo y culminación de este trabajo.

ÍNDICE GENERAL

I.	INTRODUCCIÓN	1
II.	REVISIÓN DE LITERATURA	3
2.1	DESEMPEÑO DOCENTE	3
2.1.1	DEFINICIÓN	3
2.1.2	DIMENSIONES	4
2.2	RENDIMIENTO ACADÉMICO	5
2.2.1	DEFINICIÓN	5
2.2.2	FACTORES QUE INFLUYEN EN EL RENDIMIENTO ACADÉMICO	6
2.3	AUTOCONCEPTO	7
2.3.1	DEFINICIÓN	7
2.3.2	DIMENSIONES DEL AUTOCONCEPTO.....	8
2.4	CONFIABILIDAD Y VALIDEZ DEL INSTRUMENTO DE MEDIDA	9
2.4.1	CONFIABILIDAD	9
2.4.1.1	DEFINICIÓN	9
2.4.1.2	COEFICIENTE ALFA DE CRONBACH	10
2.4.2	VALIDEZ	11
2.4.2.1	DEFINICIÓN	11
2.4.2.2	VALIDEZ DE CONTENIDO	11
2.4.2.3	VALIDEZ DEL CRITERIO	12
2.4.2.4	VALIDEZ DE CONSTRUCTO.....	12
2.5	ANÁLISIS FACTORIAL CONFIRMATORIO	13
2.6	MODELO DE ECUACIONES ESTRUCTURALES	14
2.6.1	DEFINICIÓN	14
2.6.2	MODELO.....	15
2.6.2.1	MODELO GENERAL DE ECUACIÓN ESTRUCTURAL	15
2.6.2.2	TERMINOLOGÍA BÁSICA.....	19
2.6.2.3	SUPUESTOS.....	20
2.6.3	LA FUNCIÓN DE LA TEORÍA EN LOS MODELOS DE ECUACIONES ESTRUCTURALES	21
2.6.4	CARACTERÍSTICAS	21

2.6.5	RAZONES DE USO.....	22
2.6.6	PASOS EN LA MODELIZACIÓN DE ECUACIONES ESTRUCTURALES	23
III.	MATERIALES Y MÉTODOS	39
3.1	MATERIALES	39
3.2	TIPO DE INVESTIGACIÓN.....	39
3.3	FORMULACIÓN DE LAS HIPÓTESIS DE INVESTIGACIÓN.....	39
3.4	IDENTIFICACIÓN DE VARIABLES.....	41
3.4.1	Variables Endógenas.....	41
3.4.2	Variables Exógenas.....	42
3.5	DEFINICIONES OPERACIONALES	44
3.6	DISEÑO DE LA INVESTIGACIÓN	45
3.7	POBLACIÓN Y MUESTRA	45
3.8	PROCEDIMIENTO DE ANÁLISIS DE DATOS	46
IV.	RESULTADOS Y DISCUSIÓN	48
	Etapa 1: Verificación de los requisitos de confiabilidad y validez	48
	Etapa 2: Validación del modelo de ecuación estructural.....	50
V.	CONCLUSIONES	69
VI.	RECOMENDACIONES	70
VII.	REFERENCIAS BIBLIOGRÁFICAS	71
VIII.	ANEXOS	77

ÍNDICE DE TABLAS

Cuadro 1: Operacionalización de variables	44
Cuadro 2: Porcentaje de variancia acumulada de la encuesta para medir el autoconcepto .	48
Cuadro 3: Porcentaje de variancia acumulada de la encuesta para medir el desempeño docente	49
Cuadro 4: Prueba de normalidad multivariada	54
Cuadro 5: Prueba de aleatoriedad	54
Cuadro 6: Estimación de los coeficientes del modelo	55
Cuadro 7: Estimación de las variancias	56
Cuadro 8: Medida de ajuste absoluto Chi-Cuadrado	57
Cuadro 9: Medidas de ajuste absoluto GFI , RMSEA y SRMR	57
Cuadro 10: Medidas de ajuste incremental CFI, TLI y AGFI.....	58
Cuadro 11: Medidas de ajuste de parsimonia PGFI y PNFI	58
Cuadro 12: Significancia del modelo estructural.....	59
Cuadro 13: Significancia de los coeficientes del modelo propuesto	59
Cuadro 14: Relaciones con índices de modificación mayores a 3.84 del modelo propuesto	61
Cuadro 15: Medida de ajuste absoluto Chi-Cuadrado del modelo reespecificado	62
Cuadro 16: Medidas de ajuste absoluto GFI , RMSEA y SRMR del modelo reespecificado	63
Cuadro 17: Medidas de ajuste incremental CFI, TLI y AGFI del modelo reespecificado ..	63
Cuadro 18: Medidas de ajuste de parsimonia PGFI y PNFI del modelo reespecificado	64
Cuadro 19: Comparación de las medidas obtenidas con el modelo propuesto y el reespecificado	64
Cuadro 20: Significancia del modelo estructural del modelo reespecificado	65
Cuadro 21: Significancia de los coeficientes del modelo reespecificado	66

ÍNDICE DE FIGURAS

Figura 1: Modelo de Ecuación Estructural.....	16
Figura 2: Modelo propuesto	40
Figura 3: Modelo estructural propuesto	50
Figura 4: Modelo propuesto	51
Figura 5: Gráfica del modelo propuesto.....	60
Figura 6: Modelo estructural reespecificado	62
Figura 7: Gráfica del modelo reespecificado.....	67

ÍNDICE DE ANEXOS

Anexo 1: Encuesta docente	77
Anexo 2: Encuesta de autoconcepto estudiantil	80
Anexo 3: Códigos utilizados	84
Anexo 4: Tabla completa de las relaciones y sus índices de modificación	94

RESUMEN

El propósito principal de la investigación fue comprobar si el rendimiento académico de los estudiantes en el curso de Estadística General de la Universidad Nacional Agraria La Molina (UNALM) es explicado a través de un modelo propuesto de Ecuación Estructural de tres factores. El primero denominado “desempeño docente”, medido por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos; el segundo llamado “autoconcepto”, medido por las variables: académico/laboral, social, emocional, familiar y físico y finalmente el tercero “rendimiento pasado”, medido a través del promedio ponderado acumulado. Los datos utilizados corresponden a las notas de los alumnos matriculados en el ciclo académico 2014-I en el curso de Estadística General, al promedio ponderado acumulado; y los valores se registraron en la escala de Likert de 1 al 10 de las encuestas de desempeño docente y autoconcepto. Estos dos instrumentos, cumplen con los requisitos de confiabilidad y validez al registrar en ambos casos indicadores por encima de los mínimos aceptables. El modelo de ecuación estructural propuesto fue reespecificado (mejorado) mediante la inclusión de una nueva relación de interdependencia, el rendimiento pasado como predictor del autoconcepto. Se verificó el ajuste del modelo de ecuación estructural reespecificado a través de los principales indicadores de ajuste absoluto e incremental. Entre los resultados más importantes de la investigación se verificó que el factor rendimiento pasado es el mejor predictor del factor rendimiento académico de los estudiantes en el curso de Estadística General y que los factores desempeño docente y rendimiento pasado explican al factor autoconcepto.

Palabras claves: Modelo de Ecuaciones Estructurales, rendimiento académico, desempeño docente, autoconcepto, rendimiento pasado.

ABSTRACT

The principal goal of this research is if the academic performance score into general statistics course of the National Agrarian University La Molina (UNALM) is explained through Structural Equation Modeling with three factors. The first factor professor's performance has measured by variables like: Plan targeted lessons, course's knowledge, instructions 's method, the duties of professor, the evaluate criteria, teacher's motivation and interactions in class. The second factor called self concept was measured by: academic/occupational, social, emotional, family and, physical health. Finally, the three factor is "last performance score" was measured by cumulative grade point average. Datasets are student's score, who have studied 2014-I academic semester in statistics course. The registered values was likert scale from 1 to 10 through the surveys of the professor's performance and, self concept. These two instruments have followed with requirements like reliability and validity when the indicator have been showing highest values over minimal acceptable. Structural equation model was improved by respecification of structural model through a new interdependent relationship, last performance score was predictor of the self concept. Respecification of structural model was proved by principal indicators of absolute index and incremental. The main results of this investigation proved that last performance score is the best predictor of the students performance score in statistics course so, professor's performance and last performance score have explained the self concept factor.

Keywords: Structural Equation Modeling, academic performance, teaching performance, self concept, past performance.

I. INTRODUCCIÓN

El objetivo para alcanzar una educación superior de calidad es formar profesionales altamente calificados, conscientes y responsables; así como promover, difundir y generar conocimientos a través de la investigación. En la actualidad, las universidades se encuentran comprometidas en realizar sus funciones de enseñanza, investigación y responsabilidad social con calidad, por ello vienen sometiéndose a procesos de autoevaluación, acreditación y certificación.

La Universidad Nacional Agraria La Molina (UNALM) se encuentra en la actualidad enmarcada dentro de este proceso, razón por la cual creó en el año 2004 la Unidad de Calidad y Acreditación Universitaria (UCA-UNALM) y en el año 2011 la Unidad de Innovación Educativa (UIE).

La calidad de una institución de educación superior se puede medir a través de los procesos relacionados con el quehacer universitario y actores que participan en el proceso de enseñanza-aprendizaje, es decir, profesores y estudiantes. En el caso de los estudiantes una forma de cuantificar la calidad educativa es a través del rendimiento académico, el cual depende de un conjunto de factores.

Existen varios tipos de investigaciones sobre el rendimiento académico, los tradicionales como el modelo de Fullana (1996), Juan Tonconi Quispe (2009), entre otros, cuyo interés es explicar el rendimiento académico a través de un conjunto de variables; los modernos representados por modelos estadísticos de ecuaciones estructurales como el de Parkerson, Lomas, Schiller & Walberg (1983), Gonzáles (1989) entre otros, cuyo interés es explicar el rendimiento académico en función de un conjunto de factores interrelacionados entre sí.

El Modelo de Ecuaciones Estructurales (SEM) permite evaluar simultáneamente un conjunto de relaciones de dependencia entre variables, factores o constructos que a su vez son explicados por un conjunto de variables medibles llamadas indicadores. Para esta investigación se propone un modelo del rendimiento académico en el curso de Estadística General que es explicado por tres dimensiones o factores, y a su vez cada uno de ellos es explicado por un conjunto de indicadores. El primer factor, denominado “desempeño docente” el cual es medido por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos; el segundo llamado “autoconcepto” que es medido por las variables: académico/laboral, social, emocional, familiar y físico; y finalmente el tercero “rendimiento pasado” que es medido a través del promedio ponderado acumulado.

La investigación tiene como objetivo principal validar un modelo de ecuación estructural (SEM) que explique el rendimiento académico de los estudiantes en el curso de Estadística General en la UNALM en el ciclo 2014-I; como objetivos específicos, es probar la significancia del modelo y de las relaciones planteadas.

Se justifica la investigación en la medida que las áreas involucradas con los procesos de enseñanza y aprendizaje de la universidad podrán contar con un modelo explicativo del rendimiento académico de los estudiantes en el curso de Estadística General, el mismo que les permitirá entender mejor el rendimiento académico y tomar acciones para mejorar la formación académica de sus estudiantes.

Para la presente investigación se consideró una muestra representativa de la población de estudiantes de la Universidad Nacional Agraria La Molina matriculados en el curso de Estadística General en el ciclo académico 2014-I.

II. REVISIÓN DE LITERATURA

2.1 DESEMPEÑO DOCENTE

2.1.1 DEFINICIÓN

El desempeño docente se relaciona a las distintas capacidades y competencias que el docente debe poseer como el cumplimiento, la puntualidad, el compromiso, el vínculo con el estudiante, entre otras, las cuales debe tener y desarrollar para poder participar mejor en el proceso de enseñanza y aprendizaje.

Existen diversas definiciones del desempeño docente, algunas de ellas serán mostradas a continuación:

Cahuana, citado por Monroy (2012), menciona con respecto a la definición del desempeño docente: “Que es el ejercicio práctico de una persona que ejecuta las obligaciones y roles establecidos legal, institucional y socialmente, pero que son inherentes a la profesión docente. Entre tales actividades, se mencionan la planificación y programación educativa, la facilitación del aprendizaje, el empleo de estrategias didácticas, el uso de materiales y medios didácticos, la evaluación del aprendizaje, etc. Las que configuran en su conjunto, lo esencial del proceso educativo”

Según Flores (2010) se entiende como desempeño docente "al conjunto de capacidades desplegadas por los docentes en el proceso de enseñanza- aprendizaje, dentro del aula".

Montenegro, citado por Palomino (2012), menciona que “El desempeño docente se entiende como el cumplimiento de sus funciones; éste se halla determinado por factores

asociados al propio docente, al estudiante y al entorno. Así mismo, el desempeño se ejerce en diferentes campos o niveles: el contexto socio-cultural, el entorno institucional, el ambiente de aula y sobre el propio docente una acción mediante una acción reflexiva”.

2.1.2 DIMENSIONES

Las dimensiones del desempeño docente corresponden a los distintos aspectos que incluye. Existen diversidad de dimensiones como por ejemplo el cumplimiento de las obligaciones, el método evaluativo, interacción con el estudiante, entre otras.

Según Flores (2010), son las capacidades desplegadas por los docentes en el proceso de enseñanza-aprendizaje: Planificación docente, mediación de los aprendizajes, evaluación del aprendizaje, integración de teoría y práctica, habilidades comunicacionales, actitudes y valores, responsabilidad y ética docente, respeto y tolerancia.

Zabalza, citado por Barrientos (2013), indica que el docente universitario tiene tres dimensiones: Dimensión profesional, dimensión personal y dimensión laboral.

Lescano (2002) en el estudio que realizó consideró que el Desempeño Docente tiene tres dimensiones: Capacitación Docente, Experiencia Profesional y Capacidad Didáctica.

Valdés, citado por Reyes (2016), propone un modelo de evaluación que contempla 4 dimensiones "Capacidades Pedagógicas, Emocionalidad, Responsabilidad en el Desempeño de sus Funciones y Relaciones Interpersonales".

Francis (2005) indica que hay tres dimensiones, la personal, la pedagógica y la disciplinar; entre ellas no hay una que tenga mayor jerarquía que las otras.

Palomino (2012) menciona las siguientes: “Estrategias didácticas, materiales didácticos, capacidades pedagógicas, responsabilidad en el desempeño de sus funciones”.

2.2 RENDIMIENTO ACADÉMICO

2.2.1 DEFINICIÓN

El rendimiento académico se relaciona con las capacidades y el esfuerzo que hace el estudiante para poder aprender durante y después el proceso de enseñanza y aprendizaje; lo aprendido es decir lo teórico o práctico o lo relacionado a actitudes, estos logros son cuantificados de diversas formas, una de ellas es a través de la nota en el curso, pero también se puede usar el promedio ponderado o la cantidad de créditos aprobados en la carrera u otras formas.

Además, el rendimiento académico es un concepto multidimensional que se conceptualiza de distintas formas según el enfoque que se esté utilizando como el educativo, psicológico, entre otros.

Existen diversas definiciones del rendimiento académico, algunas de ellas serán mostradas a continuación:

Bloom, citado por Guzmán (2012), lo define como "...es lo necesario para que el alumno sea capaz de llevar a la práctica sus conocimientos, que pueda aplicar la información adquirida a la solución de problemas"

Según García y Medina (2011). "El rendimiento académico es definido como el cumplimiento de las metas, logros u objetivos establecidos en cada una de las asignaturas que se cursan y que se expresa en la nota cuantitativa que el alumno obtiene "

Tournon, citado por García (2015), indica que "el rendimiento académico es un resultado del aprendizaje, suscitado por la intervención pedagógica del profesor o profesora y producido en el alumno", también Forteza citado por García (2015) define el rendimiento académico "como una serie de factores que giran alrededor de los resultados finales del esfuerzo hecho por el o la estudiante"

Pérez et al., citados por Garbanzo (2007), mencionan que es la suma de diferentes y complejos factores que actúan en el que aprende, es un valor del logro del estudiante el cuál se mide en forma cuantitativa mediante las calificaciones obtenidas.

2.2.2 FACTORES QUE INFLUYEN EN EL RENDIMIENTO ACADÉMICO

El rendimiento académico es influenciado por una gran diversidad de factores que se pueden agrupar en los de tipo personal, social, institucional, entre otros. Dependiendo del estudio a realizar se consideran ciertos factores.

Herrera et al., citado por Guzmán (2012), mencionan como variables explicativas del rendimiento académico el nivel de estudios de los padres, personalidad, inteligencia, hábitos de estudio, rendimiento anterior, entre otras. También mencionan que en la Universidad de Zaragoza se encontró que el mejor predictor de los resultados en el primer año de estudios es el rendimiento previo; Reparaz citado por Guzmán (2012) estudió una serie de variables como posibles predictores del rendimiento universitario y una de las conclusiones es que existen correlaciones significativas entre los rendimientos previos y finales.

Según Rodríguez (2007). Son varias las investigaciones que muestran la importancia del rendimiento previo en la predicción del rendimiento en la Universidad. Existen diversas formas de medir el rendimiento previo, una de ellas es el rendimiento obtenido en semestres o en años anteriores dentro de la misma Universidad. También Sánchez, es citado por Rodríguez (2007), el cual menciona "La capacidad predictiva del rendimiento previo mejora cuanto más cerca esté en el tiempo el indicador de rendimiento previo elegido del indicador del rendimiento que se desea predecir".

Garbanzo (2007) menciona los siguientes componentes que influyen en el rendimiento académico, determinantes personales (competencia cognitiva, motivación, condiciones cognitivas, entre otros), determinantes sociales (diferencias sociales, entorno familiar, nivel educativo de los progenitores o adultos responsables del estudiante, entre otros) y determinantes institucionales (elección de los estudios según interés del estudiante,

complejidad en los estudios, condiciones institucionales, relación estudiante-profesor, entre otros). Además, Castejón & Pérez, citados por Garbanzo (2007), indican que el estudiante quiere encontrar en el profesor una relación tanto afectiva como didáctica y que ello influye en el rendimiento académico.

Gargallo et al. (2008) corroboran la importancia del autoconcepto como un constructo que tiene relación con el rendimiento académico.

Según Guzman (2012) al mencionar el modelo de rendimiento en ciencias de González (1989) concluye que el rendimiento previo es un buen predictor del rendimiento posterior, también al mencionar el modelo de Reynolds y Walberg (1991) se observa que el rendimiento anterior tiene una influencia en el rendimiento en ciencias.

Muelas (2013) menciona que “Para aumentar el autoconcepto de un estudiante, la figura del docente va a ser clave.”, también que "El autoconcepto es una de las variables que, dentro del ámbito de la personalidad, tiene una incidencia mayor en el rendimiento académico (Beltrán, 1984; Marsh, 1990; Pérez y Castejón, 2006). La tendencia actual contempla una bidireccionalidad entre autoconcepto y rendimiento (Beltrán, 1984; González-Pienda, Núñez, Álvarez, Álvarez y Soler, 2002)”

2.3 AUTOCONCEPTO

2.3.1 DEFINICIÓN

El autoconcepto se entiende como la imagen que tiene un sujeto sobre sí mismo, que se va construyendo a través de las distintas experiencias de la vida, sean estas positivas o negativas; este autoconcepto puede presentarse en distintas dimensiones, una de ellas es la académica la cual influye más en el rendimiento académico de un estudiante.

Existen diversas definiciones del autoconcepto, algunas de ellas serán mostradas a continuación:

Gargallo et al. (2008) interpretan al autoconcepto como “una conceptualización del propio sujeto sobre sí mismo, que se construye en interacción con el medio, y que va acompañada de connotaciones afectivas y evaluativas importantes”.

Kalish, citado por Ecurra et al. (2005), indica que “el autoconcepto se puede definir como la imagen que cada sujeto tiene de su persona, reflejando sus experiencias y los modos en que estas experiencias se interpretan”.

Rodríguez, citado por Quintero y Zárate (2016), menciona que el autoconcepto “es la representación mental que se tiene de sí mismo...”

Navajas (2015) lo define como un proceso de análisis, de valoración e integración de informaciones que vienen de las experiencias y el feed-back externo. También Purkey citado por Navajas (2015) lo define como “un sistema de creencias complejo y dinámico donde cada individuo tiene una apreciación particular acerca de sí mismo”.

García y Musitu (2001) lo definen como “Es el concepto que el individuo tiene de sí mismo como un ser físico, social y espiritual”.

Cardenal y Fierro, citados por Veliz y Apodaca (2012), definen el autoconcepto como “un conjunto de juicios, tanto descriptivos como evaluativos acerca de uno mismo, y consideran que el autoconcepto expresa el modo en que la persona se representa, conoce y valora a ella misma”.

2.3.2 DIMENSIONES DEL AUTOCONCEPTO

Las dimensiones del autoconcepto corresponden a los distintos aspectos que incluye, y que afectan a la imagen o percepción que uno tiene de sí mismo. Existe diversidad de dimensiones como la académica, social, familiar, personal, entre otras.

González y Touron, citados por Ecurra et al. (2005), indican que el autoconcepto presenta dos componentes básicos: un componente cognoscitivo que es la autoimagen y un componente afectivo que es la autoestima.

García y Musitu (2001) en el cuestionario Autoconcepto Forma 5 (AF5) mencionan 5 dimensiones: académico/laboral, social, emocional, familiar y físico.

Burns, citado por Veliz y Apodaca (2012), indica que el autoconcepto tiene tres dimensiones básicas: cognitiva, afectiva y comportamental.

Esnaloa et al., citados por Cazalla y Molero (2013), indican que las dimensiones del autoconcepto son: físico, personal, social y académico.

2.4 CONFIABILIDAD Y VALIDEZ DEL INSTRUMENTO DE MEDIDA

Aldás y Uriel (2017) mencionan que para validar el instrumento de medida son necesarios dos pasos: estimar un análisis factorial confirmatorio, y determinar si los instrumentos de medida tienen la calidad suficiente el cual es evaluado mediante su fiabilidad y validez.

2.4.1 CONFIABILIDAD

2.4.1.1 DEFINICIÓN

Aldás y Uriel (2017) mencionan que es “la propiedad de que aplicaciones repetidas de un mismo instrumento de medida deben dar resultados consistentes”, como es complicado la administración repetida entonces lo que se evalúa es la consistencia interna del instrumento de medida. Existen diversas formas de medir la fiabilidad en términos de consistencia interna, una de ellas es mediante el coeficiente Alfa de Cronbach.

Según Hair et al.(1999), “es el grado de consistencia entre las múltiples medidas de una variable”; una forma de medirla es la consistencia interna que se aplica a la consistencia

entre las variables en una escala aditiva, el Alfa de Cronbach mide la fiabilidad valorando la consistencia de la escala entera.

2.4.1.2 COEFICIENTE ALFA DE CRONBACH

Tornimbeni et al. (2008) mencionan que permite conocer el grado en que los distintos ítems de un test miden la misma variable; si los ítems covarian fuertemente entonces el Alfa de Cronbach toma un valor cercano a uno, pero si son linealmente independientes entonces tomará un valor cercano a cero.

Según Aldás y Uriel (2017), supóngase que se tiene una escala formada por k ítems (X_1, X_2, \dots, X_k) que se ha construido para medir a la variable latente Y para calcular su fiabilidad, y se cuenta con la matriz de variancias y covariancias C.

$$C = \begin{bmatrix} \sigma_1^2 & & & & & \\ \sigma_{12}^2 & \sigma_2^2 & & & & \\ \sigma_{13}^2 & \sigma_{23}^2 & \sigma_3^2 & & & \\ \dots & \dots & \dots & \dots & \dots & \\ \sigma_{1k}^2 & \sigma_{2k}^2 & \sigma_{3k}^2 & \dots & \sigma_k^2 & \end{bmatrix}$$

Al sumar todos los elementos de la matriz se tiene la variancia total de Y. El coeficiente Alfa de Cronbach se define como la proporción de la variancia total de la escala que es atribuible a la variable Y, la parte de la variancia total que no explica la variable latente se denomina variancia específica o residual. La expresión del Alfa de Cronbach es la siguiente.

$$\alpha = \frac{k}{k-1} \left(1 - \frac{\sum \sigma_i^2}{\sigma_y^2} \right)$$

donde k es el número de elementos en la diagonal.

Si se desea trabajar en términos de correlaciones entre los ítems de la escala.

$$\alpha = \frac{k\rho}{1 + (k - 1)\rho}$$

donde ρ es la media de los coeficientes de correlación entre todos los ítems que conforman la escala.

Con respecto a los valores recomendados del Alfa de Cronbach:

Nunnally y Bernstein, citados por Aldás y Uriel (2017), afirman el que valor del Alfa de Cronbach depende de para qué vaya a utilizarse la escala, un valor de 0.7 puede ser suficiente para etapas preliminares de desarrollo de una escala, luego de las depuraciones respectivas el valor no debe bajar de 0.8.

Según Hair et al.(1999), el límite inferior para el Alfa de Cronbach es de 0.7, puede ser de 0.6 en la investigación exploratoria.

2.4.2 VALIDEZ

2.4.2.1 DEFINICIÓN

Según Aldás y Uriel (2017) una escala es válida cuando lo que está midiendo realmente es la variable latente que debería medir.

Según Malhotra (2004) se entiende "como el grado en el que las diferencias en las puntuaciones de escala observadas reflejan diferencias verdaderas entre objetos sobre la característica que se mide, más que el error sistemático o aleatorio".

2.4.2.2 VALIDEZ DE CONTENIDO

Haynes et al., citados por Aldás y Uriel (2017), mencionan que “representa el grado en que los indicadores de un instrumento de medida son relevantes y representativos de la variable

latente que quieren medir”, el proceso es cualitativo con jueces que reciben la definición y valoran en qué medida cada ítem está conectado con el concepto. Si el objetivo no es la creación de una escala, se asume que las escalas usadas de la literatura tienen validez de contenido.

Según Weiers (1986), hace referencia a la medida en que el instrumento parece estar midiendo la característica en estudio. “... este enfoque se emplea ampliamente, en especial durante las etapas formativas del diseño del instrumento, cuando el juicio de los expertos sobre la representatividad de el suele ser una fuente de aporte constructivo y de útiles sugerencias...”

2.4.2.3 VALIDEZ DEL CRITERIO

Malhotra (2004) menciona que "refleja si una escala se desempeña como se espera en relación con otras variables seleccionadas como criterio significativo (variables de criterio). Las variables del criterio pueden incluir características demográficas y psicográficas, mediciones de actitud y de conducta o calificaciones obtenidas de otras escalas. Con base en el periodo de que se trate, la validez del criterio puede tomar dos formas: validez concurrente y validez de pronóstico".

2.4.2.4 VALIDEZ DE CONSTRUCTO

Se asocia al grado en que un instrumento mide un constructo (concepto no observado en forma directa) como por ejemplo la ansiedad, el autoconcepto, entre otros. La técnica estadística del Análisis Factorial es una de las principales formas para verificar la validez de constructo.

Según Weiers (1986), “hay validez de constructo siempre que la medida de un concepto particular guarda relación con las medidas de otros conceptos afines en una forma teóricamente prevista”.

Según Aiken (2003) "...se refiere al grado en que el instrumento mide un constructo particular..."

2.5 ANÁLISIS FACTORIAL CONFIRMATORIO

Según Bollen (1989) en un Análisis Factorial Confirmatorio (CFA) el modelo se construye de antemano por el analista el cual determina el número de variables latentes, si las variables latentes influyen en las observadas, etc; en un Análisis Factorial Confirmatorio (CFA) se requiere un modelo inicial detallado.

Schumacker y Lomax (2016) mencionan que el Análisis Factorial Confirmatorio (CFA) prueba si un modelo teórico produce una matriz de variancia-covariancia similar a la matriz de variancia-covariancia de la muestra. El investigador define las variables que se asignan a los factores, las variables con carga cero indican que no hay relación, puede considerarse como una regla una carga de 0.60 o más para determinar las variables que son importantes.

En el Análisis Factorial Confirmatorio (CFA) se tienen definidos los factores y los indicadores que miden cada uno de los factores. La formalización matemática, la identificación del modelo, la estimación y otros conceptos relacionados serán mostrados el punto referido a Modelo de Ecuaciones Estructurales (SEM) ya que el CFA se considera un caso particular.

Así como hay el Análisis Factorial Confirmatorio, también se tiene el Análisis Factorial Exploratorio en donde se maneja el concepto del criterio del porcentaje de variación explicada acumulada, Garza et al.(2013) mencionan que los factores que se manejan como solución inicial deben de tener un porcentaje de variación explicada acumulada entre 60% y 95%. Hair et al. (1999) señalan que en las ciencias sociales se considera una solución que represente un 60% de la variancia total, incluso hasta menos, como satisfactoria.

2.6 MODELO DE ECUACIONES ESTRUCTURALES

2.6.1 DEFINICIÓN

Hair et al. (1999) señala que: “El modelo de ecuaciones estructurales (SEM) abarca una familia entera de modelos conocidos con muchos nombres, entre ellos análisis de la estructura de la covarianza, análisis de variable latente, análisis de factor confirmatorio y a menudo simplemente análisis LISREL (el nombre de uno de los programas de software más populares)”

Véliz (2017) menciona que “Los modelos de ecuaciones estructurales involucran una serie de relaciones entre variables numéricas (directamente medibles o no) con la finalidad de descubrir procesos subyacentes que generan las variables. Otros nombres como: modelos causales, análisis causal o análisis de la estructura de covarianza también se usan para referirse a esta técnica. Aun cuando la técnica describe correlaciones y relaciones estructurales entre las variables, ninguno de los resultados que se obtienen indican causalidad; el nombre de modelo causal o de análisis causal solo se refiere al diseño. El análisis factorial confirmatorio, el análisis factorial exploratorio y el análisis de regresión son casos particulares de esta técnica”

Hoyle (1995) menciona que el modelo de ecuación estructural es un enfoque estadístico de las hipótesis sobre las relaciones entre las variables observadas y las variables latentes.

Schumacker y Lomax (2016) mencionan que el Modelo de Ecuación Estructural (SEM) representa relaciones entre variables observadas y variables latentes en diversos tipos de modelos que son hipotetizados y probados en SEM, las hipótesis se refieren a cómo los conjuntos de variables definen constructos y como estos constructos se relacionan entre sí.

2.6.2 MODELO

2.6.2.1 MODELO GENERAL DE ECUACIÓN ESTRUCTURAL

Según Hair et al.(1999), la notación LISREL (nombre de uno de los programas de software más conocidos) se ha convertido en la notación estándar. “El modelo LISREL completo se puede expresar en términos de ocho matrices, dos definiendo las ecuaciones estructurales, dos definiendo la correspondencia de indicadores y constructos, una para la correlación de constructos exógenos, una para la correlación de los constructos endógenos y finalmente dos detallando los errores correlacionados para la medición de las variables endógenas y exógenas“

Las ecuaciones se muestran a continuación:

$$\text{Modelo estructural: } \eta = B\eta + \Gamma\xi + \zeta$$

$$\text{Modelo de medida exógeno: } X = \Lambda_x\xi + \delta$$

$$\text{Modelo de medida endógeno: } Y = \Lambda_y\eta + \varepsilon$$

Por ejemplo:

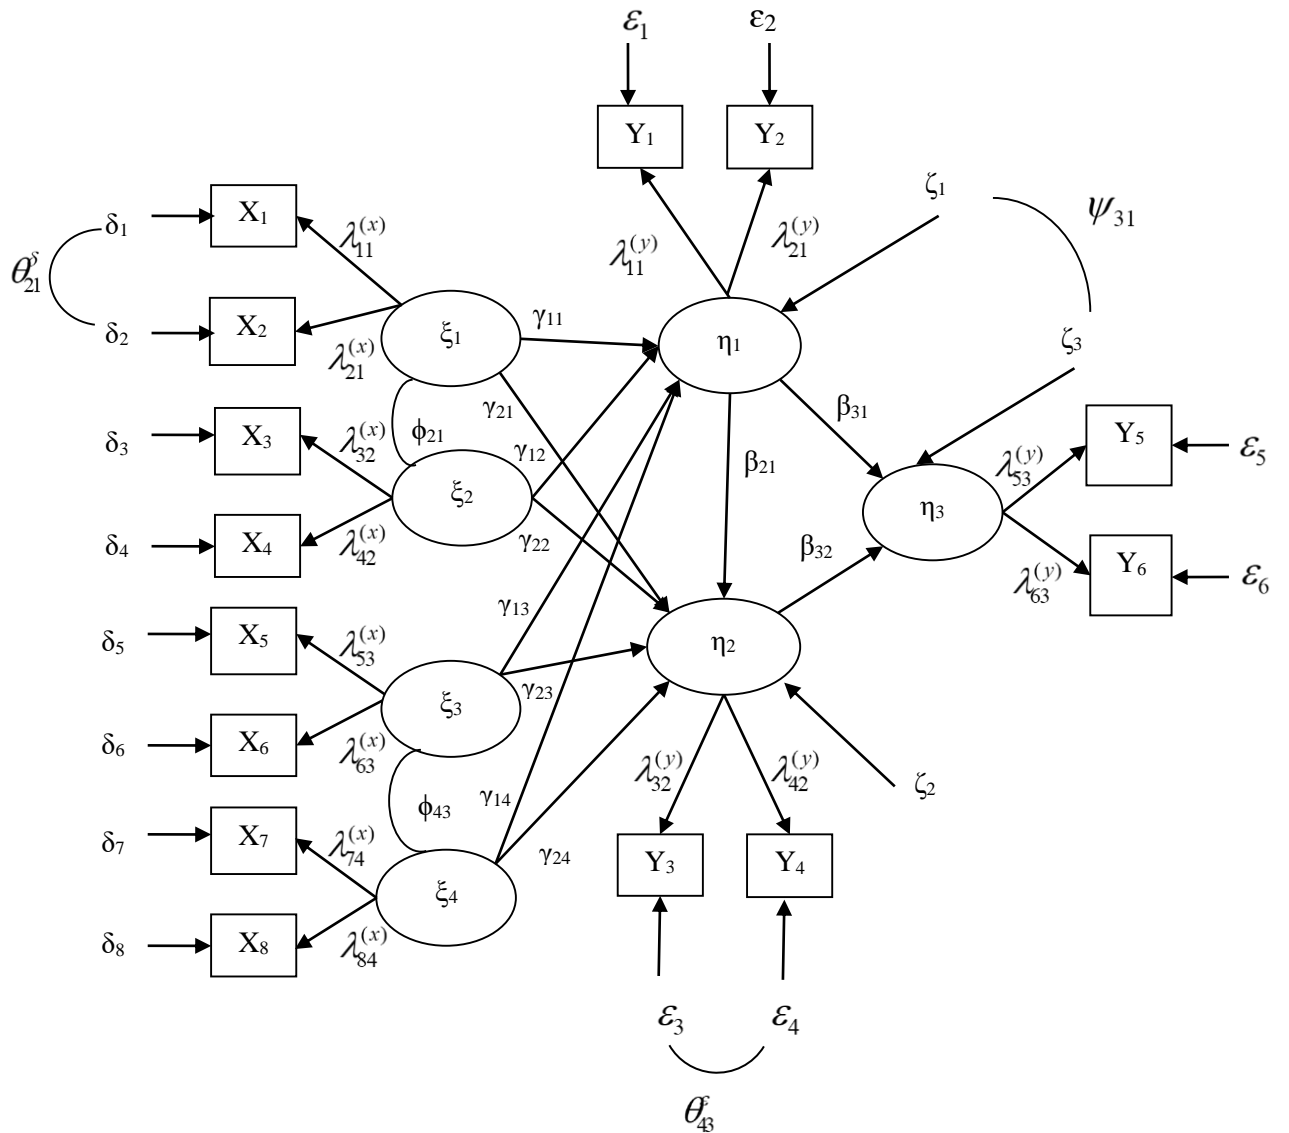


Figura 1: Modelo de Ecuación Estructural

Fuente: Recuperado de “Análisis Multivariante”, Hair et al.(1999), p.677, Madrid, España. Prentice Hall Iberia.

Como se observa en la Figura 1 en la representación gráfica de los modelos de medida y estructurales se usan ciertas convenciones: las flechas directas indican relaciones causales y las curvadas indican correlaciones, los indicadores están indicados por rectángulos y los constructos por elipses.

Para el modelo estructural:

B indica el efecto de η_j en η_j

$$B = \begin{pmatrix} 0 & 0 & 0 \\ \beta_{21} & 0 & 0 \\ \beta_{31} & \beta_{32} & 0 \end{pmatrix}$$

Γ indica el efecto de ξ_i en η_j

$$\Gamma = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \gamma_{14} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \gamma_{24} \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

Entonces el modelo estructural es el siguiente

$$\begin{pmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{pmatrix} = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \gamma_{14} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \gamma_{24} \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 \\ \beta_{21} & 0 & 0 \\ \beta_{31} & \beta_{32} & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{pmatrix} + \begin{pmatrix} \zeta_1 \\ \zeta_2 \\ \zeta_3 \end{pmatrix}$$

Para el modelo de medida:

Carga de x_k en ξ_i

$$\Lambda_x = \begin{pmatrix} \lambda_{11}^{(x)} & 0 & 0 & 0 \\ \lambda_{21}^{(x)} & 0 & 0 & 0 \\ 0 & \lambda_{32}^{(x)} & 0 & 0 \\ 0 & \lambda_{42}^{(x)} & 0 & 0 \\ 0 & 0 & \lambda_{53}^{(x)} & 0 \\ 0 & 0 & \lambda_{63}^{(x)} & 0 \\ 0 & 0 & 0 & \lambda_{74}^{(x)} \\ 0 & 0 & 0 & \lambda_{84}^{(x)} \end{pmatrix}$$

Carga de y_l en η_j

$$\Lambda_y = \begin{pmatrix} \lambda_{11}^{(y)} & 0 & 0 \\ \lambda_{21}^{(y)} & 0 & 0 \\ 0 & \lambda_{32}^{(y)} & 0 \\ 0 & \lambda_{42}^{(y)} & 0 \\ 0 & 0 & \lambda_{53}^{(y)} \\ 0 & 0 & \lambda_{63}^{(y)} \end{pmatrix}$$

Entonces el modelo de medida de ξ es:

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \\ X_7 \\ X_8 \end{pmatrix} = \begin{pmatrix} \lambda_{11}^{(x)} & 0 & 0 & 0 \\ \lambda_{21}^{(x)} & 0 & 0 & 0 \\ 0 & \lambda_{32}^{(x)} & 0 & 0 \\ 0 & \lambda_{42}^{(x)} & 0 & 0 \\ 0 & 0 & \lambda_{53}^{(x)} & 0 \\ 0 & 0 & \lambda_{63}^{(x)} & 0 \\ 0 & 0 & 0 & \lambda_{74}^{(x)} \\ 0 & 0 & 0 & \lambda_{84}^{(x)} \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \end{pmatrix} + \begin{pmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \delta_7 \\ \delta_8 \end{pmatrix}$$

Entonces el modelo de medida de η es:

$$\begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \\ Y_5 \\ Y_6 \end{pmatrix} = \begin{pmatrix} \lambda_{11}^{(y)} & 0 & 0 \\ \lambda_{21}^{(y)} & 0 & 0 \\ 0 & \lambda_{32}^{(y)} & 0 \\ 0 & \lambda_{42}^{(y)} & 0 \\ 0 & 0 & \lambda_{53}^{(y)} \\ 0 & 0 & \lambda_{63}^{(y)} \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{pmatrix}$$

2.6.2.2 TERMINOLOGÍA BÁSICA

Variables manifiestas:

Según Véliz (2017), son las que se miden de manera directa y en las gráficas se representan con rectángulos o cuadrados. “Cada indicador es explicado por la variable latente o el factor correspondiente y un error r_i y señalado con flechas que parten del factor y del error y llegan al indicador”

Aldás y Uriel (2017) mencionan que, “las variables observadas que miden un factor dependiente se las denota como Y, y a las que miden un factor independiente, como X. Las cargas factoriales de las variables observadas sobre el factor se designan como λ_x si el factor es independiente y como λ_y si es dependiente.”

Según Schumacker y Lomax (2016) las variables observadas son un conjunto de variables que se usan para definir la variable o constructo.

Variable latente o factor:

Según Véliz (2017).” En los modelos de ecuaciones estructurales también aparecen variables que no es posible medir directamente pero que se infieren a través de los valores de las variables manifiestas. Estas variables, que se llaman variables latentes o factores, se representan con círculos o elipses”.

Según Hair et al.(1999). “Una variable latente es un concepto supuesto y no observado que sólo puede ser aproximado mediante variables medibles u observables. Las variables observadas, que recogemos a través de varios métodos de obtención de datos (es decir, estudios de mercado, experimentos, observación) se conocen como variables manifiestas.”

Según Schumacker y Lomax (2016) las variables latentes son variables que no se observan y no se miden directamente, por eso se miden usando un conjunto de variables observadas.

VARIABLES INDEPENDIENTES O EXÓGENAS

Según Véliz (2016).”...que impactan hipotéticamente en las variables dependientes o endógenas...”

Según Hair et al.(1999) “ no están <<causados>> o son explicados por ninguna de las variables del modelo; esto es, no existen flechas apuntando a estos constructos”.

VARIABLES DEPENDIENTES O ENDÓGENAS

Según Hair et al.(1999) “... se predicen mediante uno o más constructos. Los constructos endógenos pueden predecir otros constructos endógenos (aquí es donde vemos las interrelaciones que apuntan a la necesidad de los modelos estructurales)”.

Según Véliz (2017) las variables dependientes o endógenas son las que son impactadas hipotéticamente por las variables independientes o exógenas.

RELACIONES DE MEDIDA O MODELO DE MEDIDA

Según Véliz (2017) son: “Las relaciones entre las variables latentes y sus indicadores...”

Según Hair et al.(1999), el modelo de medida “especifica las reglas de correspondencia entre las variables latentes y manifiestas. El modelo de medida permite al investigador utilizar una o más variables para un único concepto dependiente o independiente...”

2.6.2.3 SUPUESTOS

Según Hair et al. (1999). “SEM comparte tres supuestos con los otros métodos multivariantes ...: observaciones independientes, muestra aleatoria de los encuestados y la linealidad de todas las relaciones. Además, SEM es más sensible a las características

distribucionales de los datos, particularmente el incumplimiento de la normalidad multivariante (crítica en el uso de LISREL) o una fuerte curtosis (apuntamiento) de los datos”. “La ausencia de normalidad multivariante es particularmente problemática porque infla sustancialmente el estadístico de la chi-cuadrado y crea un sesgo alcista en valores críticos para determinar la significación de los coeficientes “

Véliz (2017) menciona que si no se cumple la normalidad se recomienda tomar muestras grandes para evitar fallas en la convergencia, estimadores imprecisos o la obtención de soluciones impropias como las variancias negativas.

2.6.3 LA FUNCIÓN DE LA TEORÍA EN LOS MODELOS DE ECUACIONES ESTRUCTURALES

Según Hair et al. (1999). “Desde una perspectiva práctica, un enfoque teórico de SEM es una necesidad porque la técnica debe ser casi completamente especificada por el investigador. Mientras que con otras técnicas multivariantes el investigador puede haber sido capaz de especificar un modelo básico y permitir que valores por defecto de los programas estadísticos <<completen>> los resultados de estimación restantes, SEM no tiene ninguna de estas características”.

Según Kline (2016) el objetivo de SEM es probar una teoría para lo cual se define un modelo que represente esa teoría teniendo construcciones plausibles medidas con variables observadas adecuadas.

2.6.4 CARACTERÍSTICAS

Según Hair et al. (1999), “todas las técnicas SEM se distinguen por dos características:

(1) estimación de relaciones de dependencia múltiples y cruzadas y (2) la capacidad de representar conceptos no observados en estas relaciones y tener en cuenta el error de medida en el proceso de estimación”.

Byrne citado por Swe et al.(2013), comparó SEM con otras técnicas multivariadas y enumeró cuatro características únicas de SEM:

(1) SEM adopta un enfoque confirmatorio para el análisis de datos especificando las relaciones entre las variables a priori. En comparación, otras técnicas multivariadas son descriptivas por naturaleza (por ejemplo, análisis factorial exploratorio), por lo que la prueba de hipótesis es bastante difícil de realizar.

(2) SEM proporciona estimaciones explícitas de los parámetros de varianza de error. Otras técnicas multivariadas no pueden ni evaluar ni corregir errores de medición. Por ejemplo, un análisis de regresión ignora el error potencial en todas las variables independientes (explicativas) incluidas en un modelo y esto plantea la posibilidad de conclusiones incorrectas debido a estimaciones de regresión engañosas.

(3) Los procedimientos SEM incorporan variables no observadas (es decir, latentes) y observadas. Otras técnicas multivariadas se basan únicamente en mediciones observadas.

(4) SEM es capaz de modelar relaciones multivariadas y estimar los efectos directos e indirectos de las variables en estudio.

2.6.5 RAZONES DE USO

Según Hair et al. (1999), las razones de su atractivo son dobles: "(1) proporciona un método directo de tratar con múltiples relaciones simultáneamente a la vez que se da eficacia estadística y (2) su capacidad para evaluar las relaciones exhaustivamente y proporcionar una transición desde el análisis exploratorio al confirmatorio".

Batista y Coenders, citado por Alegre (2004), distinguen “cinco razones por las que los modelos de ecuaciones estructurales son cada vez más utilizados actualmente en las ciencias sociales. Estos modelos permiten:

- (a) Trabajar con variables latentes, que se miden a través de indicadores, y evaluar la calidad de la medición.
- (b) Considerar los fenómenos en su verdadera complejidad desde una perspectiva más realista, abandonando la estadística uni y bivalente e incorporando múltiples variables tanto endógenas como exógenas.
- (c) Considerar conjuntamente medida y predicción, análisis factorial y path analysis, es decir evaluar los efectos de variables latentes entre sí, sin contaminación debida al error de medida.
- (d) Introducir la perspectiva confirmatoria en el modelado estadístico, lo cual permite al investigador introducir su conocimiento teórico en la especificación del modelo antes de la estimación.
- (e) Descomponer las covarianzas observadas y no sólo las varianzas, dentro de una perspectiva del análisis de la interdependencia “.

2.6.6 PASOS EN LA MODELIZACIÓN DE ECUACIONES ESTRUCTURALES

La división de los pasos fue realizada según lo que indica Hair et al. (1999)

Primer paso: Desarrollo de un modelo basado en la teoría

Hair et al. (1999) mencionan: “La fuerza y convicción con que el investigador puede asumir la causación entre dos variables no descansa en los métodos analíticos escogidos sino en la justificación teórica ofrecida por los análisis”

Según Véliz (2017). “Esta etapa comprende la formalización de las ideas que sustentan las relaciones entre las variables que describen el modelo. Esto obliga al conocimiento del marco teórico sobre el que se basan los modelos que se hipotetizan”.

Segundo paso: Construcción de un diagrama de secuencias de relaciones causales

Hair et al. (1999) indica que “Un diagrama de secuencias es más que una simple representación visual de las relaciones porque permite al investigador presentar no sólo las

relaciones predictivas entre constructos (es decir, las relaciones variable dependiente-independiente), sino también relaciones asociativas (correlaciones) entre los constructos e incluso entre los indicadores”. También menciona que el investigador define los diagramas de secuencias en términos de los constructos y luego busca variables para medir cada constructo, otro elemento son las flechas para representar las relaciones entre los constructos.

Tercer paso: Conversión de un diagrama de secuencias en un conjunto de ecuaciones estructurales y especificación del modelo de medida

Según Hair et al. (1999) “Después de desarrollar el modelo teórico y de representarlo en un diagrama de secuencias, el investigador está preparado para especificar el modelo en términos más formales. Esto se hace a través de una serie de ecuaciones que definen (1) las ecuaciones estructurales que vinculan los constructos, (2) el modelo de medida que especifica qué variables miden qué constructos y (3) una serie de matrices que indican cualquier correlación supuesta entre constructos o variables”.

También mencionan que el número mínimo de indicadores por constructo es de uno, un constructo puede ser representado por dos indicadores. No existe un límite máximo con respecto al número de indicadores por constructo, pero por cuestiones prácticas la mayoría de los constructos deberían ser representados por entre 5 y 7 indicadores.

Cuarto paso: Selección del tipo de matriz de entrada y estimación del modelo propuesto

Según Hair et al. (1999), SEM es diferente a otras técnicas multivariantes ya que utiliza solo la matriz de variancia-covarianza o de correlación como los datos de entrada. “SEM se formuló inicialmente para ser utilizada con la matriz de variancia-covarianza (de ahí su denominación habitual como análisis estructural de la covarianza). La matriz de covarianza tiene la ventaja de proporcionar comparaciones válidas entre diferentes poblaciones o muestras, característica que no es posible cuando los modelos se estiman con una matriz de correlación”. “La matriz de correlación tiene un uso muy extendido en

muchas aplicaciones. Las matrices de correlación tienen un rango común que hace posible las comparaciones directas de los coeficientes dentro de un modelo, dado que simplemente es una matriz de variancia-covariancia << estandarizada>> en la que la escala de medida de cada variable se modifica dividiendo las variancias o covariancias por el producto de las desviaciones estándar. Utilizar las correlaciones es apropiado cuando el objetivo del investigador es sólo entender el patrón de las relaciones entre constructos, pero no explicar la variancia total del constructo”. Existen diversos tipos de correlaciones, si las variables involucradas se miden métricamente entonces se usa la correlación de Pearson.

Imputación de datos ausentes:

Según Hair et al. (1999), los datos ausentes pueden tener un profundo impacto sobre la matriz de entrada de los datos. Existen diversos métodos para resolver el problema de los datos ausentes, uno de ellos es el proceso de imputación de datos. No existe un método único que de los mejores resultados, el investigador puede usar distintas aproximaciones para evaluar la estabilidad de los resultados.

Los datos ausentes pueden obedecer a un proceso aleatorio (MAR) o a un mayor nivel de aleatoriedad (MCAR), también se pueden encontrar procesos no aleatorios. Solo si se determina que el proceso de ausencia de datos es MCAR puede utilizarse una mayor cantidad de forma de tratarlos con diversos métodos de imputación.

Schafer, citado por Schumacker y Lomax (2016), menciona que hay tres tipos de falta de respuesta para los datos faltantes MCAR (completamente al azar), MAR (al azar) y MNAR (no al azar).

Según Schumacker y Lomax (2016), el análisis estadístico de los datos se afecta por los datos ausentes, es común que los paquetes estadísticos tengan valores predeterminados para manejar esa situación y existen diferentes opciones como: eliminar sujetos que tienen datos ausentes, reemplazar los datos ausentes o usar procedimientos estadísticos robustos que se puedan utilizar con datos faltantes.

Según Castro (2014) una forma de realizar la imputación múltiple es utilizando las ecuaciones encadenadas, que incorpora modelos de imputación para datos continuos (ppm), datos binarios (regresión logística), entre otros. Puede trabajar con datos que sean aleatorios (MAR) y no aleatorios (MNAR)

Según Buuren (2012) una forma para la imputación de datos multivariados es usando el algoritmo MICE. El algoritmo MICE es un método de Monte Carlo de cadena de Markov donde se observa que el espacio de estado son todos los valores imputados. Comienza con un trazo aleatorio de los datos observados e imputa los datos incompletos variable por variable, una iteración es un ciclo a través de todos los Y_j , se generan múltiples imputaciones por la ejecución del algoritmo en paralelo m veces. A continuación se describe el algoritmo MICE (Van Buuren y Groothuis-Oudshoorn, 2000, 2011) en el cuál se realizan los siguientes pasos:

- Especificar un modelo de imputación $P(Y_j^{mis} | Y_j^{obs}, Y_{-j}, R)$ por variable Y_j con $j = 1, \dots, p$.
- Por cada j completar las imputaciones iniciales Y_j^0 por trazos aleatorios de Y_j^{obs} .
- Repetir para $t = 1, \dots, T$:
- Repetir para $j = 1, \dots, p$:
- Definir $Y_{-j}^t = (Y_1^t, \dots, Y_{j-1}^t, Y_{j+1}^t, \dots, Y_p^t)$ como los datos actualmente completos excepto Y_j
- Trazar $\phi_j^t \sim P(\phi_j^t | Y_j^{obs}, Y_{-j}^t, R)$
- Trazar imputaciones $Y_j^t \sim P(Y_j^{mis} | Y_j^{obs}, Y_{-j}^t, R, \phi_j^t)$
- Fin de repetición j .
- Fin de repetición t .

Tamaño de muestra:

Según Hair et al. (1999), el tamaño de muestra tiene un papel importante en la estimación e interpretación de los resultados. No existe un criterio fijo que indique el tamaño de muestra necesario, se comenta que un mínimo puede ser de al menos cinco encuestados por cada parámetro estimado con un ratio de 10 encuestados por parámetro considerado. En caso de

que se incumpla el supuesto de normalidad entonces el ratio de los encuestados respecto de los parámetros debe aumentar.

Schumacker y Lomax (2016) mencionan que se puede realizar la estimación del tamaño de la muestra usando la fórmula común, sin embargo al usar SEM se requiere a menudo un mayor tamaño de muestra para mantener la potencia y obtener estimaciones estables de los parámetros y de los errores estándar. También menciona un conjunto de autores como Anderson y Gerbing, Boomsma Hu, Bentler y Kano, entre otros, que indican tamaños de muestra adecuados para utilizar.

Procedimiento de estimación

Según Schumacker y Lomax (2016), un modelo teórico hipotético puede tener parámetros estimados usando distintos métodos de estimación. Un problema clave cuando se estiman los parámetros, es el error estándar asociado, si este error está sesgado entonces la prueba de significación estadística del parámetro se ve afectada. Para comprobar la significación estadística del parámetro se necesita la información del cociente de la estimación del parámetro entre su error estándar.

Existen diversos métodos para la estimación de los parámetros, se describirá una parte de ellos.

El método de máxima verosimilitud

Véliz (2017) menciona que tiene la siguiente función de ajuste

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

donde p es el número de variable medibles y S es la matriz que estima a Σ . Para usar este método se debe cumplir el supuesto de normalidad de las variables y tener un tamaño de muestra suficientemente grande.

Según Hair et al. (1999), este método ofrece resultados válidos con solo 50 observaciones, pero una muestra de ese tamaño no es recomendable. No existe un tamaño muestral fijo pero se recomienda tamaños entre 100 y 200. Este método es sensible a la no normalidad.

Aldás y Uriel (2017) mencionan que en una situación donde ambos supuestos no se cumplan (normalidad multivariada e independencia entre los términos de error y los factores comunes) entonces hay que utilizar la estimación ML denominada escalada o Robusta el cual es descrito por Satorra y Bentler.

Según Rosseel (2012), si los datos no tienen una distribución normal entonces las estimaciones de los parámetros aún siguen siendo consistentes si el modelo está identificado y especificado correctamente, pero los errores estándar tenderán a ser pequeños lo que implica rechazar la hipótesis nula que indica que el parámetro es cero, y el estadístico de prueba χ^2 del modelo tenderá a ser demasiado grande. Varios autores han ampliado la metodología ML para tener errores estándar que son asintóticamente correctos para distribuciones arbitrarias y un estadístico de prueba χ^2 reescalado. También menciona que los errores estándar de los estimadores de máxima verosimilitud se basan en la matriz de covariancia, los errores estándar robustos reemplazan esta matriz de covariancia por una matriz de covariancia de tipo sándwich. Con el software R y el paquete lavaan con el argumento `se="robust"` se producen estos errores estándar robustos. El método más conocido es la prueba escalada de Satorra y Bentler, el cual cambia la escala del valor estadístico χ^2 según una cantidad que refleja el grado de curtosis, es efectivo para datos no normales y con muestras pequeñas a moderadas. Con el paquete lavaan con el argumento `test="Satorra.Bentler"` se obtiene el estadístico de prueba escalado, con el argumento `estimator="MLM"` se ajusta el modelo obteniendo los errores estándar robustos y el estadístico de prueba escalado.

El método de mínimos cuadrados no ponderados (ULS)

Según Véliz (2017) se usa la siguiente función de ajuste.

$$F_{ULS} = \left(\frac{1}{2}\right) \text{traza}(S - \Sigma(\theta))^2$$

Long y Ullman, citados por Aldás y Uriel (2017), indican que hay dos limitaciones que hacen que el método no sea muy utilizado: no existen contrastes estadísticos asociados a este tipo de estimación y los estimadores dependen de la escala de medida de las variables observadas. Pero también cuenta con una ventaja: no es necesario asumir una distribución teórica de las variables observadas frente a la hipótesis de normalidad multivariante. Si se cumple la normalidad multivariada en forma muy evidente entonces se recomienda usar como datos de entrada la matriz de variancias y covariancias estandarizada o la matriz de correlaciones.

Véliz (2017) menciona que “este método es menos eficiente que el de máxima verosimilitud; sin embargo, es más fácil de aplicar y no requiere supuesto de normalidad”

El método de mínimos cuadrados generalizados (GLS)

Según Veliz (2017), usa la siguiente función de ajuste:

$$F_{GLS} = \left(\frac{1}{2}\right) tr((S - \Sigma(\theta))S^{-1})^2$$

Se tienen buenos estimadores cuando se cumple el supuesto de normalidad y el tamaño de la muestra es cercano a 500.

Según Schumacker y Lomax (2016) con el estimador GLS se tienen las mismas propiedades que el enfoque ML bajo una suposición de normalidad multivariada menos rigurosa y proporcionan una prueba de Chi-Cuadrado aproximada del ajuste del modelo a los datos.

Quinto paso: Valoración de la identificación del modelo estructural

Según Véliz (2017), existe la necesidad de obtener estimadores únicos y de fácil interpretación, y esto está relacionado con el número de variables y parámetros que

intervienen en el modelo. El modelo será identificable si el número de parámetros (P) que son estimados es menor o igual que el número de covariancias (K) que se pueden establecer entre las variables medibles. Si $G=K-P$ es menor que cero entonces el modelo tiene infinitos estimadores y se dice que el modelo no es identificable, para corregir eso se suele imponer restricciones (fijar valores 0 y 1 como valores de los parámetros). Si $G=0$ entonces el modelo es exactamente identificable, y si $G>0$ entonces se permite la estimación y el contraste de los parámetros.

Según Hair et al. (1999), un problema de identificación es la incapacidad del modelo propuesto para generar estimaciones aisladas. No hay una regla aislada que establezca la identificación del modelo, pero si existen normas como las condiciones de orden y rango, las condiciones de orden indican que los grados de libertad del modelo deben ser mayores o iguales a cero lo cual corresponde a un modelo identificado o sobreidentificado, el modelo identificado tiene cero grados de libertad, pero lo mejor es tener un modelo sobreidentificado. Un modelo que no cumple la condición de orden se denomina modelo infraestimado el cual tiene grados de libertad negativos. La condición de rango por el cual el investigador determina algebraicamente si cada parámetro se identifica especialmente.

También mencionan los “posibles síntomas de un problema de identificación. Estos incluyen (1) errores estándar muy elevados para uno o más coeficientes, (2) la incapacidad del programa para invertir la matriz de información, (3) estimaciones muy poco razonables o estimaciones imposibles tales como variancias de error negativas, o (4) elevadas correlaciones ($\pm 0,90$ o superiores) entre los coeficientes estimados.”. La solución que mencionan para un problema de identificación es definir más restricciones para el modelo.

Sexto paso: Evaluación de los criterios de calidad de ajuste

Según Hair et al. (1999), se evalúa la calidad del ajuste a diversos niveles, es decir para el modelo conjunto y para los modelos estructurales y de medida.

Antes de evaluar el ajuste del modelo, hay que asegurarse que no existan estimaciones infractoras que se trata de coeficientes estimados en los modelos de medida o estructurales que exceden los límites aceptables.

Para evaluar el ajuste global del modelo se usan unas medidas de calidad de ajuste. SEM no tiene una única prueba estadística para evaluar el modelo, sino que hay varias que se usan en combinación. Las medidas de calidad del ajuste se clasifican en tres tipos: (1) medidas absolutas del ajuste, (2) medidas del ajuste incremental, (3) medidas de ajuste de parsimonia.

Medidas del ajuste absoluto

Según Hair et al. (1999), “Las medidas del ajuste absoluto determinan el grado en que el modelo conjunto (modelos estructural y de medida) predice la matriz de correlación o covariancia observada”. Entre estas medidas tenemos:

Estadístico Chi-cuadrado

Aldás y Uriel (2017) mencionan “Es el único estadístico para evaluar el ajuste del modelo, el resto de indicadores que comentaremos no siguen distribuciones conocidas y, por lo tanto, no pueden usarse con planteamientos inferenciales para contrastar hipótesis nulas tal como si ocurre con el estadístico χ^2 ”

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

donde: F_{ML} es la función de máxima verosimilitud.

n es el tamaño de la muestra

Según Véliz (2017) este estadístico sirve como estadístico de prueba de la hipótesis nula $H_0: \Sigma = \Sigma(\theta)$. La aplicación de este estadístico depende del tamaño de la muestra, ya que

con una muestra muy grande es probable que por error se rechace la hipótesis nula, y si la muestra es pequeña es probable que la distribución no sea Chi-Cuadrado.

Hair et al. (1999) mencionan que un valor grande de este estadístico indica que las matrices observadas y estimadas difieren en forma considerable, lo que se busca es que existan diferencias no significativas. Este estadístico es sensible a los tamaños de muestra sean pequeños o grandes, también influyen otros factores; por eso es que hay la necesidad de complementar esta medida con otras.

Según Kline (2016), el estadístico de prueba en máxima verosimilitud robusta (MLR) es generalmente el Satorra Bentler Chi-Cuadrado escalado designado como χ_{SB}^2 , el cual se calcula multiplicando por un factor de corrección de escala “c” al Chi-Cuadrado del modelo sin escala.

$$\chi_{SB}^2 = \frac{\chi_M^2}{c}$$

El valor de c refleja la curtosis promedio en los datos sin procesar. Las distribuciones de χ_{SB}^2 , sobre muestras aleatorias solo se aproximan a las distribuciones centrales de Chi-Cuadrado pero tienen promedios asintóticamente correctos.

El Chi-Cuadrado ajustado de Satorra-Bentler se basa en un factor de corrección de escala diferente, por lo que sus distribuciones siguen más de cerca las distribuciones de chi-cuadrado central con medias y varianzas asintóticamente correctas. Esta estadística tiene un grado de libertad estimado que suele ser un número fraccional que se utiliza para calcular el valor p.

Marsh et al., citados por Aldás y Uriel (2017), mencionan algunos inconvenientes o limitaciones que tiene este estadístico: con pequeños tamaños de muestra o ausencia de normalidad el estadístico no tiene una distribución χ^2 , con valores pequeños de la función de máxima verosimilitud cuando aumenta el tamaño de muestra entonces también crece el

valor de χ^2 aumentando la probabilidad de rechazar la hipótesis nula, el ajuste puede ser razonable sin que las matrices de variancias y covariancias muestral y teórica sean iguales.

Un criterio que quiere intentar resolver el problema de la χ^2 es lo planteado por Wheaton (1977) el cual introduce un ratio χ^2/df y recomienda relaciones de 3:1 a inferiores.

Según Bollen (1989), una medida ad hoc utilizada es el estimador χ^2 dividido entre sus grados de libertad, parece que la justificación es que el valor esperado de una variable que tiene una distribución χ^2 es justamente los grados de libertad, entonces χ^2/df estima cuantas veces mayor es la estimación de χ^2 que su valor esperado. Sobre los valores recomendados no hay un consenso, según Carmines y McIver (1981) recomiendan proporciones de 3,2 o menos, hasta 5.

Índice de bondad de ajuste (GFI)

Según Véliz (2017) se compara la matriz de covariancias dato y la matriz $\Sigma(\hat{\theta})$ y es una medida global de bondad de ajuste al nivel de la muestra. Se define como:

$$GFI = \frac{tr(\Sigma(\hat{\theta})^t W \Sigma(\hat{\theta}))}{tr(S^t W S)}$$

W es la matriz identidad si los estimadores son ULS

W es la matriz S si los estimadores son GLS.

W es igual a $\Sigma^{-1}(\theta)$ en el caso de los estimadores ML.

Si $GFI \geq 0.90$ entonces el modelo es aceptable.

Según Hair et al. (1999), mide el grado de ajuste conjunto (los residuos al cuadrado de la predicción comparado con los datos efectivos), toma valores desde 0 (mal ajuste) hasta 1 (ajuste perfecto), no se tiene un valor absoluto de aceptabilidad.

Según Beaujean (2014) es algo similar a R^2 en regresión en el sentido de que intenta indicar la proporción de las varianzas y covarianzas en S (muestral) representadas por el modelo, este indicador debería estar entre 0.0 y 1.0, los valores negativos son posibles, los valores cercanos a 1.0 indican un mejor ajuste.

Índice SRMR

Según Aldás y Uriel (2017) el SRMR se construye de la siguiente manera. “Si la matriz de variancias y covariancias residual (diferencia entre la muestral y la estimada) recoge lo alejadas que están las dos matrices que serían idénticas en el caso de ajuste perfecto, basta con calcular una media de los residuos para tener un buen indicador del promedio del desajuste. Si antes de calcular la media, elevamos al cuadrado las diferencias para evitar la compensación de signos positivos y negativos y luego calculamos la raíz cuadrada de la media para reajustar la escala, eso es el SRMR”, mientras más pequeño sea el valor el ajuste es mejor, Hu y Blenter (1999) indican que valores inferiores a 0.08 indican un buen ajuste.

Hu y Bentler, citados por Álvarez y Vernazza (2013), mencionan: "El SRMR es una medida absoluta de ajuste y se define como la normalización de la diferencia entre la correlación observada y la correlación pronosticada. Un valor de cero indica ajuste perfecto y un valor inferior a 0.08 se considera un buen ajuste.

Error de aproximación cuadrático medio (RMSEA)

Aldás y Uriel (2017) señalan el RMSEA propuesto por Steiger y Lind (1980) corrige el χ^2 considerando el df (grados de libertad) y el tamaño muestral, de la siguiente manera:

$$RMSEA = \sqrt{\frac{\chi^2 - df}{df(N - 1)}}$$

Browne y Cudek, citados por Aldás y Uriel (2017), mencionan que es un buen ajuste si $RMSEA < 0.05$, ajuste aceptable si $0.05 < RMSEA < 0.08$ y ajuste pobre si $RMSEA > 0.08$

Según Hair et al. (1999) mencionan que los valores desde 0.05 hasta 0.08 se consideran aceptables.

Medidas de ajuste incremental

Según Hair et al. (1999) estas medidas comparan el modelo propuesto con algún modelo de referencia (modelo nulo), generalmente el modelo nulo es uno de constructo único con los todos los indicadores midiendo perfectamente el constructo. Entre estas medidas tenemos:

Índice Tucker-Lewis (TLI)

Aldás y Uriel (2017) mencionan que se define de la siguiente manera:

$$TLI = \frac{\chi_B^2 - \frac{df_B}{df_M} \chi_M^2}{\chi_B^2 - df_B}$$

Donde χ_B^2 es el valor del estadístico Chi-Cuadrado del modelo nulo y χ_M^2 es el valor del estadístico Chi-Cuadrado del modelo propuesto.

Este indicador incorpora un factor de corrección por parsimonia utilizando los grados de libertad. El modelo tendrá buen ajuste si $TLI > 0.90$

Según Hair et al. (1999) mencionan que también se le conoce como el índice de ajuste no normado (NNFI). “Combina una medida de parsimonia en un índice comparativo entre los modelos nulos y propuestos, lo que resulta en valores que van de 0 a 1.0”

Según Álvarez y Vernazza (2013) “la diferencia entre el NFI y el NNFI, es que el NNFI, penaliza por cantidad de parámetros, y por lo tanto tiende a aceptar modelos más parsimoniosos”.

Comparative Fit Index (CFI)

Aldás y Uriel (2017) mencionan que incorpora la corrección por parsimonia como el TLI pero se evita que el indicador tome valores por encima de la unidad. Se define de la siguiente manera:

$$CFI = 1 - \frac{\chi_M^2 - df_M}{\chi_B^2 - df_B}$$

Citan a Hu y Bentler (1999) que mencionan que si $0.90 \leq CFI \leq 0.95$ el ajuste es aceptable y si $CFI > 0.95$ entonces el ajuste es bueno.

Índice GFI ajustado (AGFI)

Según Véliz (2017) se define como:

$$AGFI = 1 - \frac{1-GFI}{1-P/K}$$

Donde P es número de parámetros estimados y K es el número de covariancias dato.

Se calcula para las funciones de máxima verosimilitud y de mínimos cuadrados ordinarios. Si $AGFI=1$, entonces el modelo ajusta perfectamente a las covariancias dato.

Según Hair et al. (1999) este índice es “una extensión de GFI, ajustado por el ratio entre los grados de libertad del modelo propuesto y los grados de libertad del modelo nulo”. Si $AGFI \geq 0.90$ entonces se considera que es un nivel aceptable.

Medidas de ajuste de parsimonia

Según Hair et al. (1999), “relacionan la calidad del ajuste del modelo al número de coeficientes estimados exigidos para conseguir este nivel de ajuste”, se usa en varios casos en comparación de modelos.

Índice de ajuste normado de parsimonia (PNFI)

Según Hair et al. (1999), “tiene en cuenta el número de grados de libertad utilizados para conseguir un nivel de ajuste. La parsimonia se define en la consecución de mayores niveles de ajuste por grado de libertad utilizado (un grado de libertad por coeficiente estimado)”. Se define como:

$$PNFI = \frac{g^l_{propuesto}}{g^l_{nulo}} \times NFI$$

Se usa principalmente al comparar modelos con diferentes grados de libertad, un valor elevado de PNFI es mejor, al comparar modelo se proponen diferencias de 0.06 a 0.09.

Según Luque (2000), “es similar al NFI pero teniendo en cuenta el número de grados de libertad usados para alcanzar el nivel de ajuste”. Interesa conseguir altos valores para este indicador, al comparar modelos alternativos, diferencias entre 0.06 y 0.09 son importantes.

Índice de calidad de ajuste de parsimonia (PGFI)

Según Hair et al. (1999), se basa en un ajuste del GFI y en la parsimonia del modelo estimado. Este índice toma valores desde 0 hasta 1, valores elevados indican una mayor parsimonia. Se define como:

$$PGFI = \frac{g^l_{propuesto}}{\left(\frac{1}{2}\right)(Nv)(Nv + 1)} \times GFI$$

donde N_v =Número de variables manifiestas

Según Luque (2000) “consiste en el ajuste del GFI de manera similar al AGFI pero basado en la parsimonia del modelo estimado”, se buscan valores elevados de este índice.

Séptimo paso: Interpretación y modificación del modelo

Según Hair et al. (1999), cuando el modelo es aceptable, el investigador debe examinar los resultados y su correspondencia con la teoría utilizada; evaluar si son significativas las relaciones principales, la dirección de las relaciones, entre otras cosas. Una forma de mejorar el modelo y el ajuste es realizar un reespecificación del modelo que significa añadir o eliminar parámetros estimados del modelo original, para lo cual debe tenerse en cuenta una justificación teórica sólida.

Véliz (2017) menciona que para realizar una mejor interpretación de los resultados es necesario analizar la compatibilidad de los resultados obtenidos con el modelo hipotetizado, muchas veces se trata de corregir eso introduciendo restricciones, aumentar o quitar relaciones pero sin tener en cuenta el fundamento teórico adecuado.

Aldás y Uriel (2017) lo enfoca en dos sentidos: evaluar si los estimadores de los parámetros toman valores adecuados teóricamente, y si son significativos; para ello deberíamos observar que no hayan: correlaciones superiores a la unidad, cargas factoriales estandarizadas fuera del intervalo $[-1,+1]$, errores estándar anormalmente grandes o pequeños, estimaciones negativas de las variancias.

Ullman, citado por Aldás y Uriel (2017), menciona que hay dos razones para reespecificar un modelo, estas son, mejorar su ajuste o contrastar alguna hipótesis teórica. Los índices de modificación (MI) permiten saber qué relaciones causales pueden agregarse y qué mejoras se esperan con estas modificaciones. Los índices de modificación se calculan para cada parámetro no estimado, un MI superior a 3.84 implica que es significativo (Jaccard y Wan,1989)

III. MATERIALES Y MÉTODOS

3.1 MATERIALES

Una computadora Lenovo, Intel(R) Core(TM) i3.

Una impresora HP Laser Jet Pro M201dw.

Software R versión 3.5.1; siendo de uso los paquetes lavaan, semPlot, mice, entre otros.

3.2 TIPO DE INVESTIGACIÓN

Correlacional y causal, porque una parte de las variables que forman el modelo se correlacionan, y existe también una relación de dependencia funcional lineal entre las variables.

3.3 FORMULACIÓN DE LAS HIPÓTESIS DE INVESTIGACIÓN

Se toman en cuenta las siguientes hipótesis:

Hipótesis General:

El rendimiento académico de los estudiantes en el curso de Estadística General de la UNALM es explicado por el modelo de ecuación estructural planteado en la Figura 2:

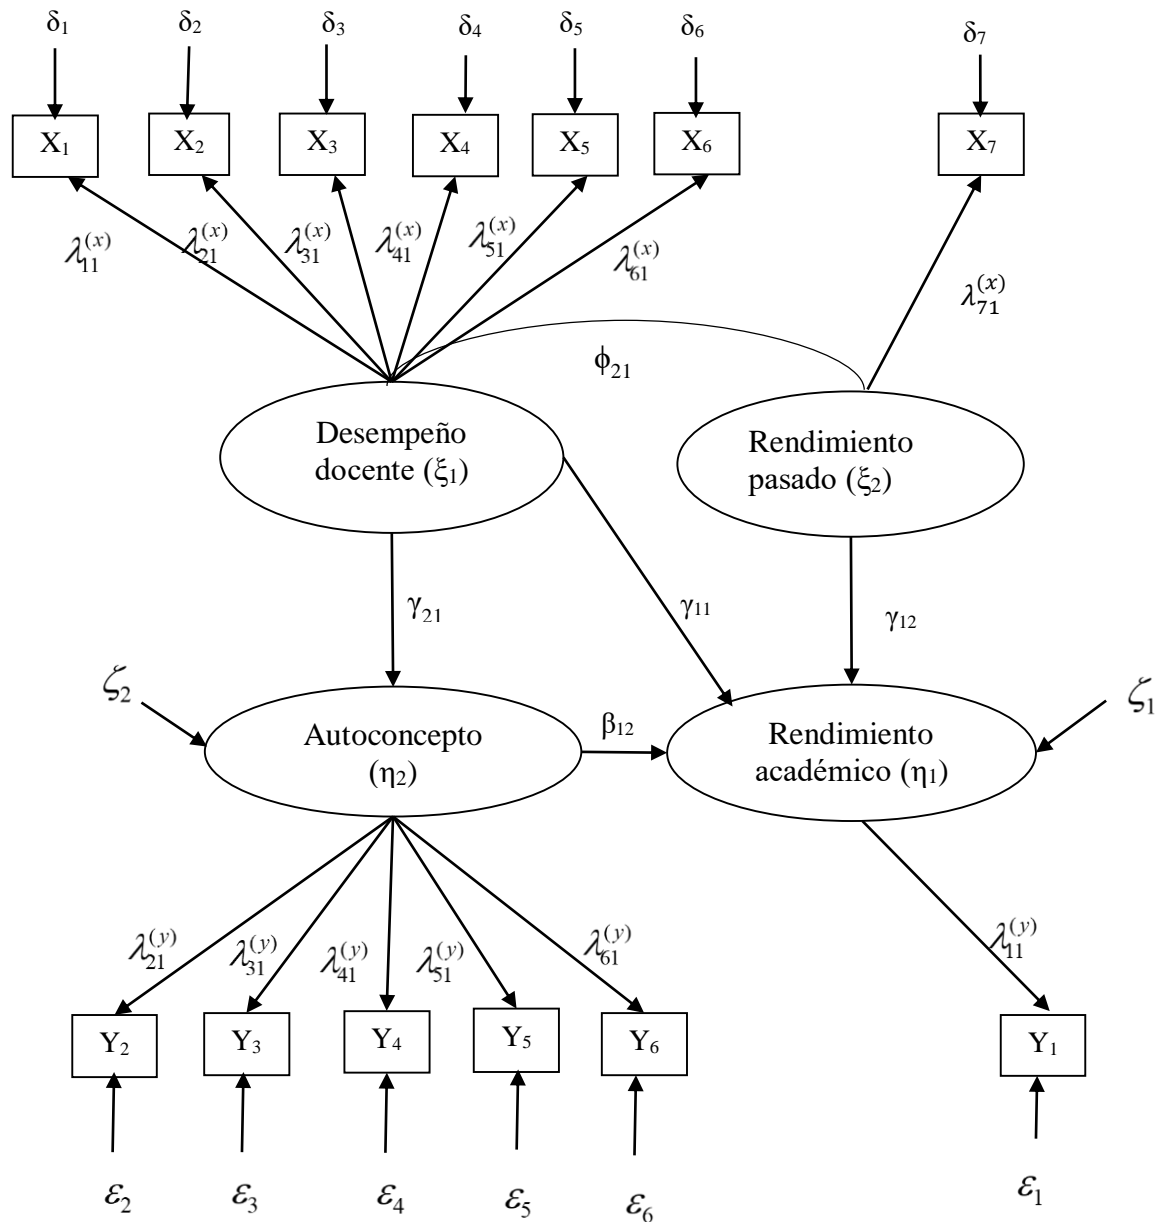


Figura 2: Modelo propuesto

Hipótesis secundaria 1:

El modelo de ecuación estructural presenta indicadores por encima de los mínimos aceptables (Ratio Chi-Cuadrado robusto entre los grados de libertad ≤ 3 , $GFI \geq 0.9$, $0.05 < RMSEA \text{ robusto} < 0.08$, $SRMR \text{ robusto} < 0.08$, $0.9 \leq CFI \text{ robusto} \leq 0.95$, $TLI \text{ robusto} > 0.9$, $AGFI \geq 0.90$, $PGFI$ y $PNFI$ con valores altos)

Hipótesis secundaria 2:

El factor desempeño docente se mide por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos.

Hipótesis secundaria 3:

El factor autoconcepto se mide por las variables: autoconcepto académico/laboral, autoconcepto social, autoconcepto emocional, autoconcepto familiar y autoconcepto físico.

Hipótesis secundaria 4:

El factor autoconcepto depende del factor desempeño docente.

3.4 IDENTIFICACIÓN DE VARIABLES

3.4.1 Variables Endógenas

η_1 : Rendimiento académico en el curso de Estadística General.

Resultado del proceso de enseñanza-aprendizaje de un alumno del curso de Estadística General.

η_2 : Autoconcepto

Percepción de sí mismo como un ser físico, social y espiritual; que tiene un estudiante del curso de Estadística General

Sub variables del Autoconcepto:

Y₂: Autoconcepto académico/laboral

Percepción que tiene el sujeto sobre la calidad en el desempeño de sus roles como estudiante y trabajador. En ambos ámbitos hay una diferenciación de periodos cronológicos, ambos se relacionan a contextos de trabajo.

Y₃: Autoconcepto social

Percepción que tiene el sujeto acerca de su desempeño en las relaciones sociales. Dos ejes la definen, el primero es la red social y la facilidad o dificultad de mantenerla o ampliarla, el segundo corresponde a algunas cualidades importantes.

Y₄: Autoconcepto emocional

Percepción del sujeto de su estado emocional y de las respuestas que tiene.

Y₅: Autoconcepto familiar

Percepción del sujeto en la implicación, participación e integración en el ambiente familiar.

Y₆: Autoconcepto físico

Percepción que tiene el sujeto de su aspecto físico y de su condición física.

3.4.2 Variables Exógenas

ξ₁: Desempeño docente en el aula

X₁: Planificación del curso

Evalúa la percepción estudiantil sobre la planificación y organización del curso. Considera la adecuada estructura lógica de los temas, el nivel de desarrollo de cada uno de los temas, entre otros aspectos.

X₂: Dominio del curso

Evalúa la percepción estudiantil sobre el dominio que el docente del curso. Considera el tratamiento claro, ordenado y profundo en las clases; así como la soltura y satisfacción que demuestra el profesor.

X₃: Métodos y recursos de instrucción

Evalúa la percepción estudiantil sobre el uso de los métodos y recursos de instrucción (trabajos grupales, exposiciones, aula virtual, etc)

X₄: Obligaciones docentes

Evalúa la percepción estudiantil sobre el cumplimiento de las obligaciones docentes (inicia y termina la clase a la hora que corresponde, asiste normalmente a la clase, etc)

X₅: Método evaluativo

Evalúa la percepción estudiantil sobre los aspectos relacionados a la evaluación (imparcialidad, realización de evaluaciones periódicas, etc)

X₆: Motivación e interacción con los alumnos

Evalúa la percepción estudiantil sobre la forma en que interactúa el profesor con sus estudiantes y aspectos relacionados a la motivación (interés por el aprendizaje de los alumnos, etc)

ξ_2 : Rendimiento pasado

Performance académica del estudiante antes de llevar el curso de Estadística General en la UNALM.

3.5 DEFINICIONES OPERACIONALES

Cuadro 1: Operacionalización de variables

VARIABLES O FACTORES	SUB VARIABLES	INDICADORES
η_1 : Rendimiento académico en el curso de Estadística General	Y_1 : Rendimiento en el curso.	Nota final en el curso de Estadística General
ξ_1 : Desempeño docente en el aula	X_1 : Planificación del curso	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	X_2 : Dominio del curso	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	X_3 : Métodos y recursos de instrucción	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	X_4 : Obligaciones docentes	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	X_5 : Método evaluativo	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	X_6 : Motivación e interacción con los alumnos	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
ξ_2 : Rendimiento pasado	X_7 : Rendimiento pasado en los cursos	Promedio ponderado acumulado
η_2 : Autoconcepto	Y_2 : Autoconcepto académico/laboral	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	Y_3 : Autoconcepto social	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	Y_4 : Autoconcepto emocional	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	Y_5 : Autoconcepto familiar	Puntaje promedio de las preguntas en escala de Likert de 1 al 10
	Y_6 : Autoconcepto físico	Puntaje promedio de las preguntas en escala de Likert de 1 al 10

3.6 DISEÑO DE LA INVESTIGACIÓN

El diseño es no experimental de corte transversal. No experimental porque las variables independientes no son manipuladas por el investigador, y de corte transversal porque los datos se recolectan en un único momento en el tiempo.

3.7 POBLACIÓN Y MUESTRA

Población: Constituido por 368 registros de los estudiantes del curso de Estadística General matriculados en el ciclo académico 2014-I.

Muestra: Se calculó una muestra representativa de 338 registros de los estudiantes del curso de Estadística General matriculados en el semestre 2014-I.

Tamaño de la población	: N=368
Error de precisión	: d=0.02
Nivel de confianza	: NC = 99%
Proporción de éxito	: p=0.5
Proporción de fracaso	: q=1-p=0.5

$$n = \frac{N \times Z_{(1-\alpha/2)}^2 \times p \times q}{d^2 \times (N - 1) + Z_{(1-\alpha/2)}^2 \times p \times q}$$

$$n = \frac{368 \times 2.5758^2 \times 0.5 \times 0.5}{0.02^2 \times (368 - 1) + 2.5758^2 \times 0.5 \times 0.5} = 338.079 \approx 338$$

Luego del proceso de selección e imputación multivariada de datos usando el algoritmo MICE (imputación múltiple por ecuaciones encadenadas), se mantuvo el tamaño óptimo de muestra en 338 registros.

3.8 PROCEDIMIENTO DE ANÁLISIS DE DATOS

Para el procesamiento de los datos se usaron los siguientes indicadores y/o técnicas estadísticas (1) Coeficiente de Confiabilidad de Alfa de Cronbach para verificar la confiabilidad de los instrumentos: encuesta de desempeño docente (modelo de encuesta estudiantil proporcionada por el profesor Fernando Rosas Villena, docente de la UNALM) y encuesta de autoconcepto (modificación de la encuesta AF5 (García y Musitu, 2001)), (2) Análisis Factorial Confirmatorio para verificar la validez de los instrumentos, y (3) Modelo de Ecuaciones Estructurales (SEM) para comprobar las interrelaciones del modelo y reespecificar el modelo en caso requiera. La investigación se llevó a cabo en tres etapas:

Etapa 1: Confiabilidad y validez

Confiabilidad: Para medir la confiabilidad de los instrumentos, desempeño docente y autoconcepto, se usa el Coeficiente Alfa de Cronbach.

Validez: Para validar los instrumentos desempeño docente y autoconcepto, se usa el Análisis Factorial Confirmatorio.

Etapa 2: Validación del modelo de ecuación estructural

Se consideró los 7 pasos indicados por Hair et al. (1999)

Primer paso: Desarrollo de un modelo basado en la teoría

Segundo paso: Construcción de un diagrama de secuencias de relaciones causales

Tercer paso: Conversión de un diagrama de secuencias en un conjunto de ecuaciones estructurales y especificación del modelo de medida

Cuarto paso: Selección del tipo de matriz de entrada y estimación del modelo propuesto

Quinto paso: Valoración de la identificación del modelo estructural

Sexto paso: Evaluación de los criterios de calidad de ajuste

Séptimo paso: Interpretación y modificación del modelo.

Etapa 3: Propuesta del nuevo modelo de ecuación estructural

Como parte de la metodología, tomando como base lo indicado en el paso séptimo se hizo una reespecificación del modelo en base a un criterio (se usó los índices de modificación) y tomando como base lo que indicó la parte teórica es decir el desarrollo del modelo basado en la teoría.

IV. RESULTADOS Y DISCUSIÓN

El análisis de los resultados se realizó tomando en cuenta tres etapas: (1) verificación de los requisitos de confiabilidad y validez de los instrumentos utilizados (encuestas), (2) validación del modelo de ecuación estructural y (3) reespecificación o propuesta de un nuevo modelo de ecuación estructural.

Etapas 1: Verificación de los requisitos de confiabilidad y validez

Encuesta para medir el autoconcepto:

Confiabilidad:

La confiabilidad es medida por el Coeficiente de Confiabilidad Alfa de Cronbach. Se obtuvo un valor de 0.80, el cual es considerado adecuado para el estudio por encontrarse en el rango de por lo menos 0.80.

Validez:

La validez es medida con el Análisis Factorial Confirmatorio. Se obtuvo un valor de 61.6% como porcentaje de variancia acumulada, el cuál es considerado adecuado por ser mayor del 60%.

Cuadro 2: Porcentaje de variancia acumulada de la encuesta para medir el autoconcepto

	TC3	TC1	TC2	TC4	TC5
SS loadings	4.365	3.972	3.795	3.351	3.008
Proportion Var	0.146	0.132	0.127	0.112	0.100
Cumulative Var	0.146	0.278	0.404	0.516	0.616

Encuesta para medir el desempeño docente:

La confiabilidad es medida por el Coeficiente de Confiabilidad Alfa de Cronbach. Se obtuvo un valor de 0.939, el cuál es considerado adecuado para el estudio por encontrarse en el rango de por lo menos 0.80.

Validez:

La validez es medida con el Análisis Factorial Confirmatorio. Se obtuvo un valor de 67.5% como porcentaje de variancia acumulada, el cuál es considerado adecuado por ser mayor del 60%.

Cuadro 3: Porcentaje de variancia acumulada de la encuesta para medir el desempeño docente

	RC1	RC2	RC3	RC5	RC6	RC4
SS loadings	3.941	2.828	2.809	2.589	2.394	1.649
Proportion Var	0.164	0.118	0.117	0.108	0.100	0.069
Cumulative Var	0.164	0.282	0.399	0.507	0.607	0.675

Etapa 2: Validación del modelo de ecuación estructural

Primer paso: Desarrollo de un modelo basado en la teoría

De acuerdo a lo señalado en el marco teórico, se sustenta las interrelaciones entre los factores del modelo. En la investigación se establecen las siguientes interrelaciones: el rendimiento pasado es predictor del rendimiento académico, el autoconcepto es predictor del rendimiento académico y el desempeño docente es predictor del rendimiento académico y del autoconcepto.

Segundo paso: Construcción de un diagrama de secuencias de relaciones causales

Con las interrelaciones planteadas en el primer paso, en la Figura 3 se propone un modelo estructural donde el desempeño docente y rendimiento pasado son constructos exógenos, y el rendimiento académico y autoconcepto son constructos endógenos.

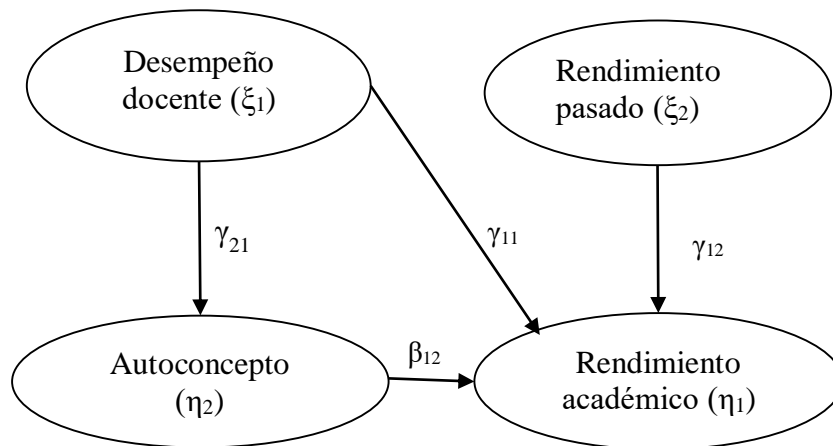


Figura 3: Modelo estructural propuesto

Tercer paso: Conversión de un diagrama de secuencias en un conjunto de ecuaciones estructurales y especificación del modelo de medida

En la Figura 4 se puede observar los constructos que son parte del modelo, así como las relaciones existentes y los indicadores que los miden.

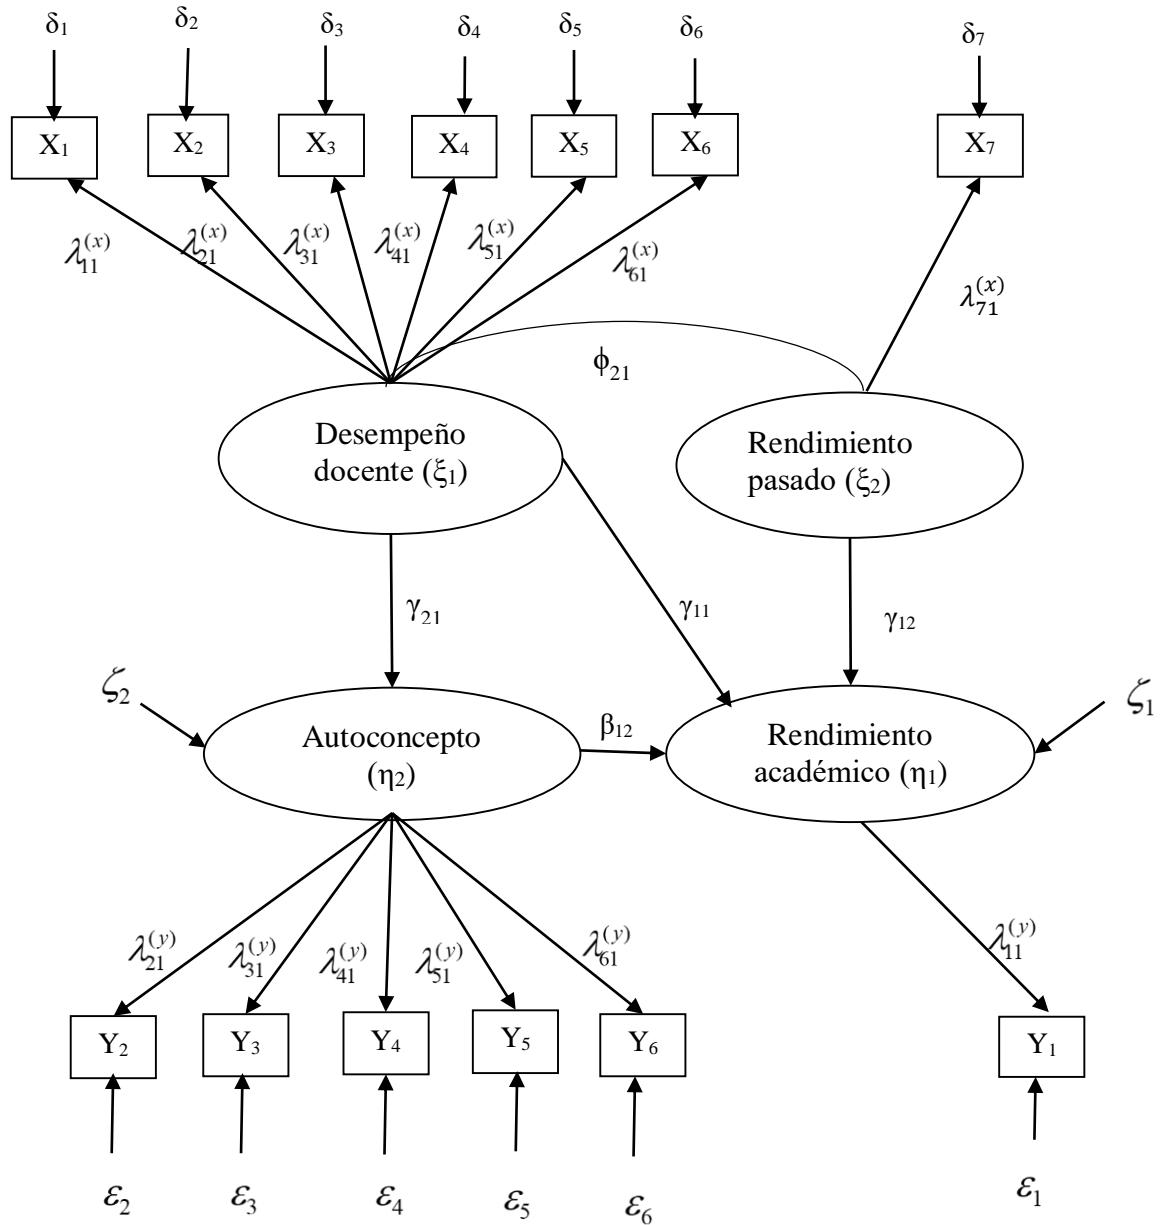


Figura 4: Modelo propuesto

En la Figura 4 también, se puede reconocer el modelo estructural (relaciones entre constructos) y el modelo de medida (relaciones entre constructos e indicadores) y a partir de estas relaciones se definen las ecuaciones para cada uno de los modelos.

Las ecuaciones del modelo estructural se expresan de la siguiente forma:

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

$$\begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} = \begin{pmatrix} 0 & \beta_{12} \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & 0 \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \end{pmatrix} + \begin{pmatrix} \zeta_1 \\ \zeta_2 \end{pmatrix}$$

$$\eta_1 = \beta_{12}\eta_2 + \gamma_{11}\xi_1 + \gamma_{12}\xi_2 + \zeta_1$$

$$\eta_2 = \gamma_{21}\xi_1 + \zeta_2$$

Las ecuaciones del modelo de medida se expresan de la siguiente manera.

Modelo de medida exógeno (ξ): $X = \Lambda_x\xi + \delta$

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \\ X_7 \end{pmatrix} = \begin{pmatrix} \lambda_{11}^{(x)} & 0 \\ \lambda_{21}^{(x)} & 0 \\ \lambda_{31}^{(x)} & 0 \\ \lambda_{41}^{(x)} & 0 \\ \lambda_{51}^{(x)} & 0 \\ \lambda_{61}^{(x)} & 0 \\ 0 & \lambda_{72}^{(x)} \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \end{pmatrix} + \begin{pmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \delta_7 \end{pmatrix}$$

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

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

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

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

$$X_5 = \lambda_{51}^{(x)} \xi_1 + \delta_5$$

$$X_6 = \lambda_{61}^{(x)} \xi_1 + \delta_6$$

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

Modelo de medida endógeno (η): $Y = \Lambda_y \eta + \varepsilon$

$$\begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \\ Y_5 \\ Y_6 \end{pmatrix} = \begin{pmatrix} \lambda_{11}^{(y)} & 0 \\ 0 & \lambda_{22}^{(y)} \\ 0 & \lambda_{32}^{(y)} \\ 0 & \lambda_{42}^{(y)} \\ 0 & \lambda_{52}^{(y)} \\ 0 & \lambda_{62}^{(y)} \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{pmatrix}$$

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

$$Y_2 = \lambda_{22}^{(y)} \eta_2 + \varepsilon_2$$

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

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

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

$$Y_6 = \lambda_{62}^{(y)} \eta_2 + \varepsilon_6$$

Cuarto paso: Selección del tipo de matriz de entrada y estimación del modelo propuesto

En el Cuadro 4 se muestra el test de Henze-Zirkler y se puede observar que los datos no cumplen con el supuesto de normalidad multivariada (p-value = 0.000), es por ello, que para evaluar el ajuste del modelo se utilizó la estadística de prueba escalada de Satorra-Bentler y los errores estándar se corrigen para garantizar su robustez utilizando un estimador tipo sandwich. Para la estimación del modelo a partir de los datos de entrada no se requería indicarle de una matriz de entrada (covariancias o correlación). Luego del proceso de selección de los registros, habían 36 que tenían datos ausentes en por lo menos uno de los ítems por lo que para tratar estos datos ausentes primero se verificó la aleatoriedad de los mismos por cada una de las encuestas (docente y autoconcepto), para

ello se usó la prueba de Little's MCAR tests que analiza la hipótesis nula de que los datos faltantes son MCAR (completamente aleatorios), en el Cuadro 5 se observa que para la encuesta docente se obtuvo un p-value de 0.157 y para la encuesta de autoconcepto un p-value de 0.817, en ambos casos son mayores a 0.05 por lo que se concluye que ambos conjuntos de datos son MCAR, por lo tanto finalmente se usó un método de imputación multivariante usando el algoritmo MICE (imputación múltiple por ecuaciones encadenadas), con lo cual se imputó los datos faltantes y se tuvo en total los 338 registros para el análisis de los datos.

Cuadro 4: Prueba de normalidad multivariada

	Test	HZ	p value	MVN
1	Henze-Zirkler	1.05854	0	NO

Cuadro 5: Prueba de aleatoriedad

```
LittleMCAR(bloque2)$p.value
this could take a while[1] 0.1566155
LittleMCAR(bloque3)$p.value
this could take a while[1] 0.8170196
```

Quinto paso: Valoración de la identificación del modelo estructural

En el Cuadro 6 se observa que al no existir mensajes de advertencia en la salida del software R entonces no se han producido errores en el proceso de estimación, y tampoco hay errores estándar elevados.

Cuadro 6: Estimación de los coeficientes del modelo

Latent Variables:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
d_docente =~						
planificacion	1.176	0.057	20.580	0.000	1.176	0.856
dominio_curso	1.063	0.055	19.243	0.000	1.063	0.877
metodos_recrss	1.056	0.066	15.890	0.000	1.056	0.758
cumplimiento	0.932	0.081	11.558	0.000	0.932	0.709
metodo_evalutv	1.075	0.067	16.163	0.000	1.075	0.748
motivcn_ntrccn	1.140	0.070	16.200	0.000	1.140	0.814
d_autoconcepto =~						
academico	0.869	0.096	9.012	0.000	0.936	0.723
social	0.728	0.095	7.640	0.000	0.783	0.506
emocional	-0.489	0.106	-4.636	0.000	-0.527	-0.302
familiar	0.639	0.081	7.932	0.000	0.688	0.504
fisico	0.764	0.139	5.512	0.000	0.822	0.376
rendimiento_curso =~						
notacurso	2.976	0.131	22.671	0.000	3.732	1.000
rendimiento_pasado =~						
prom_pond_ac	1.674	0.067	24.830	0.000	1.674	1.000
Regressions:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
rendimiento_curso ~						
d_docente	0.096	0.065	1.491	0.136	0.077	0.077
d_autoconcepto	0.004	0.069	0.062	0.950	0.004	0.004
rendimient_psd	0.734	0.072	10.191	0.000	0.585	0.585
d_autoconcepto ~						
d_docente	0.398	0.085	4.684	0.000	0.370	0.370
Covariances:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
d_docente ~~						
rendimient_psd	0.167	0.059	2.806	0.005	0.167	0.167

En el Cuadro 7 se observa que las variancias estimadas de cada uno de los indicadores son positivas y por lo tanto el modelo está identificado.

Cuadro 7: Estimación de las variancias

Variances:	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.planificacion	0.505	0.061	8.232	0.000	0.505	0.267
.dominio_curso	0.338	0.038	8.946	0.000	0.338	0.230
.metodos_recrss	0.827	0.096	8.579	0.000	0.827	0.426
.cumplimiento	0.859	0.098	8.773	0.000	0.859	0.497
.metodo_evalutv	0.911	0.151	6.030	0.000	0.911	0.441
.motivcn_ntrccn	0.662	0.103	6.453	0.000	0.662	0.338
.academico	0.800	0.175	4.567	0.000	0.800	0.477
.social	1.786	0.177	10.079	0.000	1.786	0.744
.emocional	2.774	0.189	14.713	0.000	2.774	0.909
.familiar	1.388	0.166	8.361	0.000	1.388	0.746
.fisico	4.114	0.315	13.077	0.000	4.114	0.859
.notacurso	0.000				0.000	0.000
.prom_pond_ac	0.000				0.000	0.000
d_docente	1.000				1.000	1.000
.d_autoconcepto	1.000				0.863	0.863
.rendimient_crs	1.000				0.636	0.636
rendimient_psd	1.000				1.000	1.000

Sexto paso: Evaluación de los criterios de calidad de ajuste

Procedimiento de análisis con el modelo propuesto o inicial:

En el sexto paso se hace una evaluación de los siguientes criterios de calidad de ajuste del modelo; Chi-Cuadrado, GFI, RMSEA, SRMR, CFI, TLI, AGFI, PGFI y PNFI para determinar si las relaciones planteadas son correctas de acuerdo a las fundamentaciones teóricas.

En el Cuadro 8 al aplicar el criterio de la medida de ajuste absoluto Chi-Cuadrado no se puede utilizar el p-valor de la hipótesis del ajuste del modelo por el incumplimiento del supuesto de normalidad multivariada. Por ello, en este caso se utiliza como indicador de ajuste del modelo el ratio del Chi-Cuadrado robusto entre los grados de libertad (χ^2/df) que para este caso fue de 187.159/62 el cual resultó un valor de 3.02 el cuál es un valor medianamente aceptable al ser cercano a tres.

Cuadro 8: Medida de ajuste absoluto Chi-Cuadrado

Optimization method	NLMINB	
Number of free parameters	29	
Number of observations	338	
Estimator	ML	Robust
Model Fit Test Statistic	228.418	187.159
Degrees of freedom	62	62
P-value (Chi-square)	0.000	0.000
Scaling correction factor for the Satorra-Bentler correction		1.220

En el Cuadro 9 se presentan en forma conjunta los criterios de medidas de ajuste absoluto: GFI, RMSEA y SRMR los cuales no involucran el cálculo de un p-value y la determinación de una prueba de hipótesis para probar la significancia del ajuste del modelo. El valor del GFI de 0.908 al ser mayor que 0.90 indica que el modelo tiene un buen ajuste, el valor del RMSEA robusto de 0.085 está ligeramente fuera del rango aceptable de $< 0.05 - 0.08 >$ por lo que se concluye que es marginalmente aceptable y el valor de SRMR robusto de 0.082 es ligeramente mayor a 0.08 por lo que se concluye que tiene un ajuste marginalmente aceptable.

Cuadro 9: Medidas de ajuste absoluto GFI , RMSEA y SRMR

Medida	Valor
GFI	0.908
RMSEA robusto	0.085
SRMR robusto	0.082

En el Cuadro 10 se muestran las medidas de ajuste incremental que también permiten evaluar el ajuste del modelo. El valor del CFI robusto de 0.912 se encuentra dentro del rango aceptable [0.90 - 0.95]. El valor del TLI robusto de 0.889 al ser cercano al valor límite del rango aceptable mayor a 0.90, se le considera que medianamente tiene un buen ajuste y el valor de AGFI de 0.865 al ser cercano al valor límite del rango aceptable que es mayor o igual 0.90 entonces se le considera medianamente aceptable.

Cuadro 10: Medidas de ajuste incremental CFI, TLI y AGFI

Medida	Valor
CFI robusto	0.912
TLI robusto	0.889
AGFI	0.865

En el Cuadro 11 se presentan las medidas que son útiles para evaluar el nivel de complejidad del modelo (parsimonia) cuando este valor se compara con el de otros modelos. Los niveles de parsimonia PGFI de 0.618 y PNFI de 0.696 serán utilizados cuando se comparen con los que se obtengan en el modelo reespecificado.

Cuadro 11: Medidas de ajuste de parsimonia PGFI y PNFI

Medida	Valor
PGFI	0.618
PNFI	0.696

Séptimo paso: Interpretación y modificación del modelo

Procedimiento de análisis con el modelo propuesto o inicial

En este paso se evalúa la significancia de las relaciones propuestas, así como determinar si es posible mejorar el ajuste del modelo.

En el Cuadro 12 se observa que el rendimiento pasado es el mejor predictor del rendimiento académico en el curso de Estadística General debido a que la prueba de hipótesis resulta altamente significativa ($p\text{-value} = 0.000$, $\alpha = 0.01$); el autoconcepto y el desempeño docente no son buenos predictores debido a que la prueba de hipótesis resultan en ambos casos no significativas ($p\text{-value} = 0.950$, $p\text{-value} = 0.136$). También, se logra comprobar que el desempeño docente explica al autoconcepto debido a que la prueba de hipótesis resulta altamente significativa ($p\text{-value} = 0.000$, $\alpha = 0.01$).

Cuadro 12: Significancia del modelo estructural

Regressions:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
rendimiento_curso ~						
d_docente	0.096	0.065	1.491	0.136	0.077	0.077
d_autoconcepto	0.004	0.069	0.062	0.950	0.004	0.004
rendimient_psd	0.734	0.072	10.191	0.000	0.585	0.585
d_autoconcepto ~						
d_docente	0.398	0.085	4.684	0.000	0.370	0.370

En el Cuadro 13 se comprueba que es altamente significativa las hipótesis que el desempeño docente es explicado por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos.

También se comprueba que es altamente significativa las hipótesis que el autoconcepto es explicado por las variables: autoconcepto académico/laboral, autoconcepto social, autoconcepto emocional, autoconcepto familiar y autoconcepto físico.

Cuadro 13: Significancia de los coeficientes del modelo propuesto

Latent Variables:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
d_docente =~						
planificacion	1.176	0.057	20.580	0.000	1.176	0.856
dominio_curso	1.063	0.055	19.243	0.000	1.063	0.877
metodos_recrss	1.056	0.066	15.890	0.000	1.056	0.758
cumplimiento	0.932	0.081	11.558	0.000	0.932	0.709
metodo_evalutv	1.075	0.067	16.163	0.000	1.075	0.748
motivcn_ntrccn	1.140	0.070	16.200	0.000	1.140	0.814
d_autoconcepto =~						
academico	0.869	0.096	9.012	0.000	0.936	0.723
social	0.728	0.095	7.640	0.000	0.783	0.506
emocional	-0.489	0.106	-4.636	0.000	-0.527	-0.302
familiar	0.639	0.081	7.932	0.000	0.688	0.504
fisico	0.764	0.139	5.512	0.000	0.822	0.376
rendimiento_curso =~						
notacurso	2.976	0.131	22.671	0.000	3.732	1.000
rendimiento_pasado =~						
prom_pond_ac	1.674	0.067	24.830	0.000	1.674	1.000

La Figura 5 muestra el modelo de ecuación estructural con las relaciones entre los constructos, las relaciones de los constructos con sus indicadores y las cargas estandarizadas que muestran la importancia de la capacidad explicativa entre constructos. Se observó que la mayor capacidad explicativa del rendimiento en el curso de Estadística General se debe al rendimiento pasado (0.59) y le sigue el autoconcepto explicado por el desempeño docente (0.37).

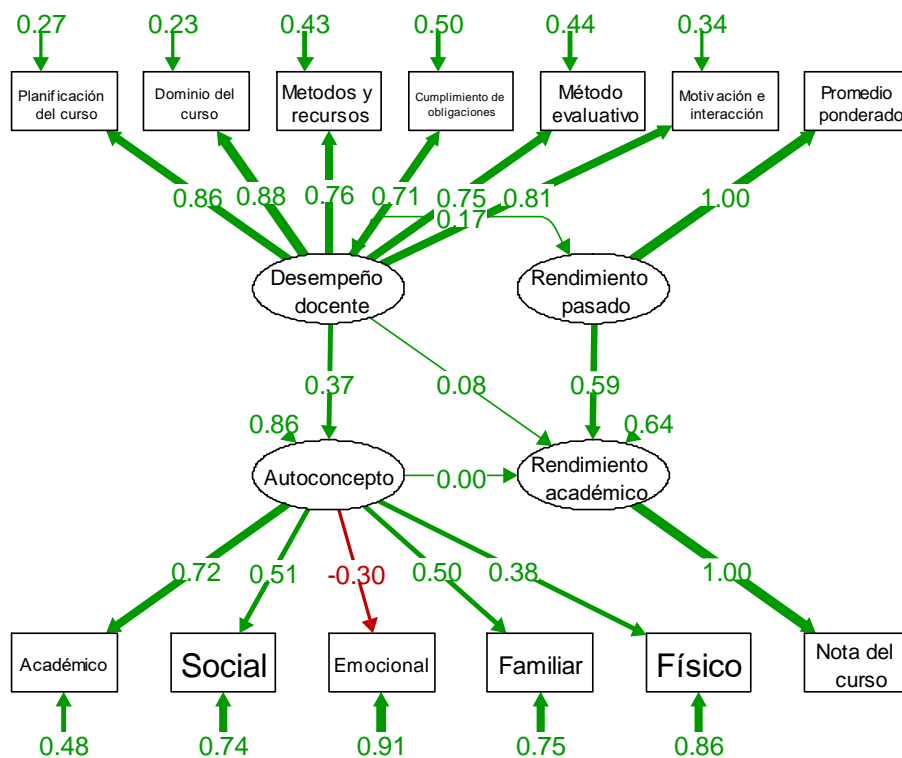


Figura 5: Gráfica del modelo propuesto

Etapa 3: Propuesta del nuevo modelo de ecuación estructural o reespecificado

En esta etapa se realizó la mejora del ajuste del modelo, es decir la reespecificación del modelo. Este procedimiento implica añadir o eliminar relaciones en el modelo original, utilizando como criterio los índices de modificación.

En el Cuadro 14 se muestran las relaciones de los índices de modificación seleccionados de una salida inicial con 120 relaciones (Ver Anexo 4). Se utilizó como criterio de selección

todas las relaciones con índice de modificación mayor a 3.84 que la literatura sugiere para reducir el número de relaciones que deben ser evaluadas. Luego de este filtro quedaron 41 relaciones que fueron evaluadas en función a sus relaciones de interdependencia sustentadas a partir de la literatura y con criterio lógico. Finalmente, se determinó que relación que indica que el autoconcepto es explicado por el rendimiento pasado es la que deberá ser incorporada al modelo, para posteriormente reiniciar el procedimiento para encontrar un modelo con mejor ajuste.

Cuadro 14: Relaciones con índices de modificación mayores a 3.84 del modelo propuesto

	lhs	op	rhs	mi	epc
69	rendimiento_pasado	=~	academico	51.044	0.432
57	rendimiento_curso	=~	academico	49.342	0.377
36	d_docente	=~	academico	24.106	0.452
61	rendimiento_curso	=~	fisico	22.927	-0.439
73	rendimiento_pasado	=~	fisico	22.314	-0.537
137	academico	~~	prom_pond_ac	17.884	0.358
133	academico	~~	emocional	15.308	0.503
138	social	~~	emocional	14.840	-0.535
37	d_docente	=~	social	14.810	-0.371
62	rendimiento_curso	=~	prom_pond_ac	14.424	100.672
159	d_autoconcepto	~	rendimiento_pasado	14.354	0.263
50	d_autoconcepto	=~	prom_pond_ac	14.354	0.428
156	d_autoconcepto	~~	rendimiento_pasado	14.354	0.256
164	rendimiento_pasado	~	d_autoconcepto	14.354	0.256
158	d_autoconcepto	~	rendimiento_curso	14.354	0.358
153	d_docente	~~	d_autoconcepto	14.353	-1.536
161	d_docente	~	d_autoconcepto	14.352	-1.536
163	rendimiento_pasado	~	rendimiento_curso	14.288	59.842
160	d_docente	~	rendimiento_curso	14.140	-357.438
108	cumplimiento	~~	metodo_evaluativo	9.855	0.171
70	rendimiento_pasado	=~	social	9.780	-0.242
58	rendimiento_curso	=~	social	9.772	-0.197
47	d_autoconcepto	=~	metodo_evaluativo	8.217	0.198
66	rendimiento_pasado	=~	cumplimiento	8.190	-0.153
89	dominio_curso	~~	metodo_evaluativo	8.180	-0.118
38	d_docente	=~	emocional	8.151	0.312
90	dominio_curso	~~	motivacion_interaccion	8.034	0.110
136	academico	~~	notacurso	7.803	0.594
54	rendimiento_curso	=~	cumplimiento	7.772	-0.119
123	metodo_evaluativo	~~	notacurso	7.513	0.449
118	metodo_evaluativo	~~	academico	6.923	0.159
92	dominio_curso	~~	social	6.834	-0.137
150	fisico	~~	notacurso	6.004	-0.839
122	metodo_evaluativo	~~	fisico	5.812	-0.275
88	dominio_curso	~~	cumplimiento	5.731	-0.093
151	fisico	~~	prom_pond_ac	5.715	-0.364
79	planificacion	~~	motivacion_interaccion	5.706	-0.106
55	rendimiento_curso	=~	metodo_evaluativo	4.505	0.095
72	rendimiento_pasado	=~	familiar	4.425	0.143
144	emocional	~~	fisico	4.287	-0.409
110	cumplimiento	~~	academico	4.201	-0.119

En la Figura 6 se muestra el modelo estructural reespecificado o modificado.

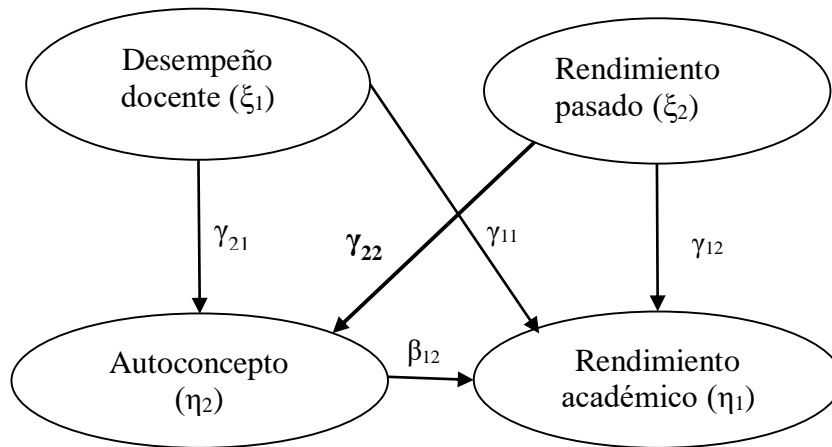


Figura 6: Modelo estructural reespecificado

Procedimiento de análisis con el modelo reespecificado:

Tomando como base el modelo estructural modificado se realiza nuevamente la evaluación de los indicadores. En el Cuadro 15 se aplica el criterio de la medida de ajuste absoluto Chi-Cuadrado. Se utiliza como indicador de ajuste del modelo el ratio del Chi-Cuadrado robusto entre los grados de libertad (χ^2/df) que para este caso fue de 165.686/61 el cual resultó un valor de 2.716 el cuál es un valor aceptable al ser menor a tres. Se observa la mejoría con respecto al modelo original que tuvo un ratio de 3.02.

Cuadro 15: Medida de ajuste absoluto Chi-Cuadrado del modelo reespecificado

Optimization method	NLMINB	
Number of free parameters	30	
Number of observations	338	
Estimator	ML	Robust
Model Fit Test Statistic	202.037	165.686
Degrees of freedom	61	61
P-value (Chi-square)	0.000	0.000
Scaling correction factor for the Satorra-Bentler correction		1.219

En el Cuadro 16 se presentan en forma conjunta los criterios de medidas de ajuste absoluto: GFI, RMSEA y SRMR. El valor del GFI de 0.912 al ser mayor que 0.90 indica que el modelo tiene un buen ajuste, el valor del RMSEA robusto de 0.079 está dentro del rango aceptable de $< 0.05 - 0.08 >$ por lo que se concluye que es aceptable y el valor de SRMR robusto de 0.073 es menor a 0.08 por lo que se concluye que tiene un ajuste aceptable. Se observa mejoría con respecto al modelo original.

Cuadro 16: Medidas de ajuste absoluto GFI , RMSEA y SRMR del modelo reespecificado

Medida	Valor
GFI	0.912
RMSEA robusto	0.079
SRMR robusto	0.073

En el Cuadro 17 se muestran las medidas de ajuste incremental que también permiten evaluar el ajuste del modelo. El valor del CFI robusto de 0.927 se encuentra dentro del rango aceptable de 0.90 y 0.95. El valor del TLI robusto de 0.906 al ser mayor a 0.90, se le considera que tiene un buen ajuste; y el valor de AGFI de 0.869 al ser cercano al valor límite del rango aceptable que es mayor o igual 0.90 entonces se le considera medianamente aceptable.

Cuadro 17: Medidas de ajuste incremental CFI, TLI y AGFI del modelo reespecificado

Medida	Valor
CFI robusto	0.927
TLI robusto	0.906
AGFI	0.869

En el Cuadro 18 se presentan las medidas que son útiles para evaluar el nivel de complejidad del modelo (parsimonia) cuando este valor se compara con el de otros modelos. Los niveles de parsimonia PGFI de 0.611 y PNFI de 0.696 serán útiles cuando sean comparados con los obtenidos en el modelo reespecificado.

Al comparar el PNFI de este modelo reespecificado que resultó con un valor de 0.696 con el del modelo propuesto el cual resultó un valor de 0.696, se concluye que no hay diferencias sustanciales entre ambos modelos puesto que la diferencia entre estos indicadores no se encuentra en el rango establecido que corresponde a diferencias entre 0.06 y 0.09

Al comparar el PGFI de este modelo reespecificado que resultó con un valor de 0.611 con el del modelo propuesto el cual resultó un valor de 0.618, se concluye que el modelo propuesto tiene una mayor parsimonia lo cual era de esperarse.

Cuadro 18: Medidas de ajuste de parsimonia PGFI y PNFI del modelo reespecificado

Medida	Valor
PGFI	0.611
PNFI	0.696

En el cuadro 19 se muestra un comparativo entre las medidas obtenidas con el modelo propuesto y el reespecificado, en el cuál se puede visualizar mejor la mejora en el modelo reespecificado.

Cuadro 19: Comparación de las medidas obtenidas con el modelo propuesto y el reespecificado

Medida	Modelo propuesto	Modelo reespecificado
Ratio Chi-Cuadrado robusto entre los grados de libertad	3.02	2.716
GFI	0.908	0.912
RMSEA robusto	0.085	0.079
SRMR robusto	0.082	0.073
CFI robusto	0.912	0.927
TLI robusto	0.889	0.906
AGFI	0.865	0.869
PGFI	0.618	0.611
PNFI	0.696	0.696

En el Cuadro 20 se observa que el rendimiento pasado es el mejor predictor del rendimiento académico en el curso de Estadística General debido a que la prueba de hipótesis resulta altamente significativa (p-value = 0.000, $\alpha = 0.01$); el autoconcepto y el desempeño docente no son buenos predictores debido a que la prueba de hipótesis resultan en ambos casos no significativas (p-value = 0.170, p-value = 0.260). También, se logra comprobar que el desempeño docente explica al autoconcepto debido a que la prueba hipótesis resulta altamente significativa (p-value = 0.000, $\alpha = 0.01$) y que el rendimiento pasado explica al autoconcepto debido a que la prueba de hipótesis resulta altamente significativa (p-value = 0.000)

Cuadro 20: Significancia del modelo estructural del modelo reespecificado

Regressions:	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
rendimiento_curso ~						
d_docente	0.068	0.061	1.126	0.260	0.054	0.054
d_autoconcepto	0.079	0.057	1.372	0.170	0.072	0.072
rendimient_psd	0.708	0.073	9.761	0.000	0.563	0.563
d_autoconcepto ~						
d_docente	0.381	0.083	4.572	0.000	0.331	0.331
rendimient_psd	0.369	0.075	4.946	0.000	0.320	0.320

En el Cuadro 21 con respecto al desempeño docente las relaciones establecidas resultaron altamente significativas (p-value= 0.000), por lo que se concluyó que el desempeño docente se mide por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos.

Con respecto al autoconcepto las relaciones establecidas resultaron altamente significativas (p-value= 0.00) por lo que se concluyó que el autoconcepto se mide por las variables: autoconcepto académico/laboral, autoconcepto social, autoconcepto emocional, autoconcepto familiar y autoconcepto físico.

Cuadro 21: Significancia de los coeficientes del modelo reespecificado

Latent Variables:	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
d_docente =~						
planificacion	1.177	0.057	20.640	0.000	1.177	0.857
dominio_curso	1.063	0.055	19.235	0.000	1.063	0.877
metodos_recrss	1.056	0.067	15.862	0.000	1.056	0.757
cumplimiento	0.932	0.081	11.554	0.000	0.932	0.709
metodo_evalutv	1.077	0.066	16.190	0.000	1.077	0.749
motivcn_ntrccn	1.140	0.070	16.206	0.000	1.140	0.814
d_autoconcepto =~						
academico	1.078	0.113	9.504	0.000	1.241	0.959
social	0.494	0.081	6.099	0.000	0.569	0.367
emocional	-0.227	0.083	-2.747	0.006	-0.262	-0.150
familiar	0.469	0.064	7.313	0.000	0.540	0.396
fisico	0.506	0.117	4.324	0.000	0.582	0.266
rendimiento_curso =~						
notacurso	2.967	0.131	22.686	0.000	3.733	1.000
rendimiento_pasado =~						
prom_pond_ac	1.674	0.067	24.830	0.000	1.674	1.000

La Figura 7 muestra el modelo de ecuación estructural modificado con las relaciones entre los constructos, las relaciones de los constructos con sus indicadores y las cargas estandarizadas que muestran la importancia de la capacidad explicativa entre constructos.

La relación con mayor capacidad explicativa es la del rendimiento en el curso de Estadística General respecto al rendimiento pasado (0.56), le sigue el autoconcepto mediante el desempeño docente (0.33) y autoconcepto a través del rendimiento pasado (0.32).

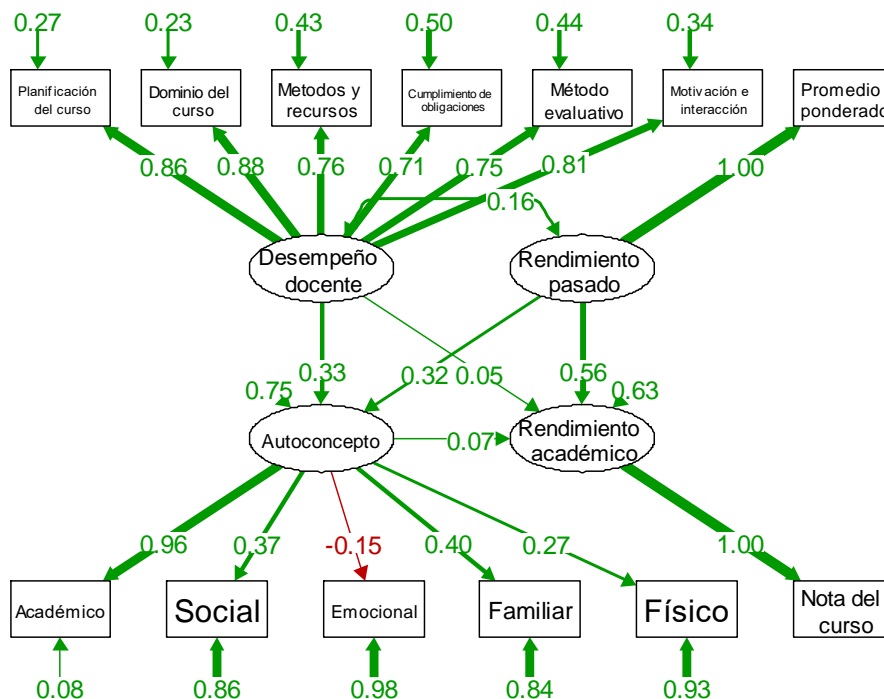


Figura 7: Gráfica del modelo reespecificado

Discusión de los resultados:

Para las encuestas del autoconcepto y desempeño docente, al evaluar su confiabilidad y validez se obtuvieron resultados adecuados; lo cual respalda el hecho de que estos instrumentos validados dan resultados consistentes en el ámbito universitario.

Cuando en el modelo propuesto se incluye la relación, el rendimiento pasado explica al autoconcepto, se respalda el hecho que es una relación importante puesto que el modelo reespecificado obtiene en general mejores indicadores de ajuste que el modelo propuesto.

Con el modelo propuesto y el reespecificado se encontró que el rendimiento pasado es el mejor predictor del rendimiento académico en el curso de Estadística General, mientras que el autoconcepto y el desempeño docente no son buenos predictores. En diversos estudios individuales, se ha logrado comprobar que el rendimiento pasado, el desempeño docente y el autoconcepto son buenos predictores del rendimiento académico de un estudiante universitario, sin embargo, cuando participan en forma simultánea estas tres

variables solo el rendimiento pasado explica significativamente al rendimiento académico de un estudiante en el curso de Estadística General, esto se debe principalmente a que los estudiantes que logran adecuarse a las exigencias académicas de la universidad llegan a establecer cierta consistencia en su rendimiento académico, además es respaldado por la teoría educativa y por las evidencias empíricas en el ejercicio profesional en la docencia universitaria. En cuanto a la no significancia del desempeño docente podría explicarse por la naturaleza del curso de Estadística General, pertenece a la componente educativa de Estudios Generales; es estandarizado en cuanto a desarrollo de contenidos y materiales usados y relativamente estandarizado en cuanto a evaluación y metodología de enseñanza. La no significancia del autoconcepto se puede explicar porque en la investigación está constituido por cinco dimensiones (académico, social, emocional, familiar y físico) de las cuales no todas tienen un impacto muy fuerte sobre el rendimiento académico. La explicación del autoconcepto por el desempeño docente se corrobora por lo que algunos autores señalan respecto a que es una de las variables que dentro del ámbito de la personalidad tiene una incidencia mayor en el rendimiento académico.

Además con el modelo reespecificado se encontró que el rendimiento pasado explica al autoconcepto, esto se sustenta en el hecho que la conceptualización que se forja el estudiante sobre sí mismo (autoconcepto) se construye en interacción con el medio y que es acompañada de connotaciones afectivas y evaluativas importantes, como su rendimiento académico pasado.

V. CONCLUSIONES

1. El rendimiento académico de los estudiantes matriculados en el ciclo académico 2014-I en el curso de Estadística General de la Universidad Nacional Agraria La Molina se explica por el modelo propuesto y con mejores indicadores de ajuste por el modelo reespecificado de ecuaciones estructurales.
2. El modelo propuesto y el modelo reespecificado de ecuaciones estructurales presentan indicadores de validez por encima de los mínimos aceptables.
3. En el modelo de ecuación estructural propuesto y el reespecificado, resultó significativo que el factor desempeño docente se mide por las variables: planificación del curso, dominio del curso, métodos y recursos de instrucción, obligaciones docentes, método evaluativo, y motivación e interacción con los alumnos.
4. En el modelo de ecuación estructural propuesto y el reespecificado, resultó significativo que el factor autoconcepto se mide por las variables: autoconcepto académico/laboral, autoconcepto social, autoconcepto emocional, autoconcepto familiar y autoconcepto físico.
5. En el modelo de ecuación estructural propuesto y el reespecificado, resultó significativo que el factor autoconcepto depende del factor desempeño docente.
6. En el modelo de ecuación estructural reespecificado, resultó significativo que el rendimiento académico depende del rendimiento pasado y que el autoconcepto depende del rendimiento pasado.

VI. RECOMENDACIONES

1. Se recomienda incluir en el modelo de ecuación estructural el factor motivación para evaluar su participación en el modelo que explica el rendimiento de los estudiantes en el curso de Estadística General.
2. Se recomienda considerar en el modelo de ecuación estructural sólo la variable dimensión académica que tuvo mayor capacidad explicativa del factor autoconcepto y excluir las otras variables con menor capacidad explicativa: dimensión social, dimensión emocional, dimensión familiar y dimensión física.
3. Se recomienda que las áreas académicas utilicen resultados de la investigación para poder comprender mejor las interrelaciones de los factores que influyen en el rendimiento académico de los estudiantes en el curso de Estadística General.
4. Se recomienda que la UNALM diseñe estrategias de mejora en las variables asociadas al desempeño docente en el curso de Estadística General debido al impacto que éstas tienen sobre el autoconcepto de los estudiantes.
5. Se recomienda que la UNALM diseñe estrategias educativas conducentes a elevar el nivel académico de los estudiantes en la Universidad Nacional Agraria La Molina debido al impacto que tiene rendimiento pasado y este último sobre el autoconcepto.
6. Se recomienda que la UNALM diseñe estrategias psico-educativas conducentes a fortalecer el autoconcepto de sus estudiantes.

VII. REFERENCIAS BIBLIOGRÁFICAS

Aiken, LR. 2003. Tests psicológicos y evaluación. 11 ed. México. Pearson Educación. p.99

Aldas, J; Uriel, E. 2017. Análisis multivariante aplicado con R. 2 ed. Madrid, España. Ediciones Paraninfo, S.A. p.499,500,502,508,509,513,514,516,517,531,533-536,542, 543,570.

Alegre Vidal, J. 2004. La gestión del conocimiento como motor de la innovación. España. Universitat Jaume I. p.99

Álvarez, R; Vernazza, E. 2013. Aplicación de los modelos de ecuaciones estructurales para el estudio de la satisfacción estudiantil en los cursos superiores de FCCEEyA (en línea). Montevideo, Uruguay. Universidad de la República.p.12-13. Consultado el 10 de feb. del 2019. Disponible en http://www.iesta.edu.uy/wp-content/uploads/2009/07/DT_13_02.pdf

Barrientos Jiménez, E. 2013. Las características de los docentes universitarios (en línea). Lima-Perú. Investigación Educativa. Vol. 17, N.º 2. UNMSM. p.106. Consultado el 25 set. 2018. Disponible en <http://disde.minedu.gob.pe/bitstream/handle/123456789/2936/Las%20caracter%C3%ADsticas%20de%20los%20docentes%20universitarios.pdf?sequence=1&isAllowed=y>

Beaujean, AA. 2014. Latent Variable Modeling Using R. Baylor University. New York, Routledge. p.163.

Bollen, KA. 1989. Structural Equations with Latent Variables. The University of North Carolina at Chapel Hill. North Carolina. John Wiley & Sons, Inc. p.228,278.

Buuren, S. 2012. Flexible Imputation of Missing Data. Londres. Taylor & Francis Group. p. 110.

Castro Cacabelos, M. 2014. Imputación de datos faltantes en un modelo de tiempo de fallo acelerado / en línea). Tesis Máster. España. Consultado el 18 de abr. 2018. Disponible en http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_940.pdf

Cazalla-Luna, N; Molero, D. 2013. Revisión teórica sobre el autoconcepto y su importancia en la adolescencia (en línea). Revista Electrónica de Investigación y Docencia (REID), 10, Julio, 2013. p.49. Consultado el 13 ene 2019. Disponible en <https://revistaselectronicas.ujaen.es/index.php/reid/article/viewFile/991/818>

Escurre Mayaute, LM; Delgado Vásquez, A; Guevara Ortega, G; Torres Valladares, M; Quesada Murillo, MR; Morocho Seminario, J; Rivas Castro, G; Santos Islas, J. 2005. Relación entre el autoconcepto de las competencias, las metas académicas y el rendimiento en alumnos universitarios de la ciudad de Lima (en línea). Lima, Perú. UNMSM. Revista IIPSI, Vol. 8 - N.º 1. p.88. Consultado el 26 oct. 2018. Disponible en <http://revistasinvestigacion.unmsm.edu.pe/index.php/psico/article/view/4235/11630>

Flores, E. 2010. El desempeño docente universitario: concepciones de los alumnos versus concepciones de los profesores (en línea). Lima, Perú. PUCP.p.4-5. Consultado el 13 set. 2018. Disponible en http://congreso.pucp.edu.pe/vi-cidu/docs/doc_comunicaciones/texto/TC-COM-103.pdf

Francis Salazar, S. 2006. Hacia una caracterización del docente universitario "excelente": Una revisión a los aportes de la investigación sobre el desempeño del docente universitario (en línea). San Pedro, Montes de Oca, Costa Rica. Universidad de Costa Rica. Educación, vol. 30, núm. 1. p.36. Consultado el 30 set. 2018. Disponible en <http://www.redalyc.org/pdf/440/44030103.pdf>

Gargallo López, B; Garfella Esteban, PR; Sánchez Peris, F; Ros Ros, C; Serra Carbonell, B. 2009. La influencia del autoconcepto en el rendimiento académico en estudiantes universitarios (en línea). Universidad de Valencia. REOP. Vol. 20, N°1, 1er Trimestre.

p.18, 24. Consultado el 25 oct 2018. Disponible en <https://www2.uned.es/reop/pdfs/2009/20-1%20-%20Bernardo%20Gargallo.pdf>

Garbanzo Vargas, GM. 2007. Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública (en línea). San Pedro, Montes de Oca, Costa Rica. Universidad de Costa Rica. Educación, vol. 31, núm. 1, p.46,48,53,57,58. Consultado el 25 oct. 2018. Disponible en <http://www.redalyc.org/pdf/440/44031103.pdf>

García, F; Musitu, G. 2001. Autoconcepto Forma 5. 2 ed. Madrid, España. Publicaciones de Psicología Aplicada. Serie menor núm.265. p.19,20.

García Moreno, M; Medina Flores, MS. 2011. Factores que influyeron en el proceso de integración a la Universidad Católica y en el rendimiento académico de los alumnos que ingresaron en el 2004-I procedentes de los diferentes departamentos del Perú (en línea). Tesis Magíster. Lima, Perú. PUCP. p.98. Consultado el 30 set. 2018. Disponible en http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/1233/GARCIA_MAGALY_MEDINA_MARIA_FACTORES_INFLUYERON.pdf?sequence=1

García Tinisaray, DK. 2015. Construcción de un modelo para determinar el rendimiento académico de los estudiantes basado en learning analytics (análisis del aprendizaje), mediante el uso de técnicas multivariantes (en línea). Tesis Doctor. Sevilla, España. Universidad de Sevilla. p.36. Consultado el 19 set. 2018. Disponible en <https://idus.us.es/xmlui/bitstream/handle/11441/40436/Tesis%20realizada%20por%20Daysi%20K.%20Garc%C3%ADa.pdf?sequence=1>

Garza García, J; Morales Serrano, BN; Gonzáles Cavazos, BA. 2013. Análisis Estadístico Multivariante.1 ed. México. McGRAW-HILL/INTERAMERICANA EDITORES. p.357

Guzmán Brito, MP. 2012. Modelos predictivos y explicativos del rendimiento académico universitario: caso de una institución privada en México (en línea). Tesis doctor. Madrid, España. Universidad Complutense de Madrid.p.54,58,69-70,120,123. Consultado el 13 set. 2018. Disponible en <https://eprints.ucm.es/15335/1/T33748.pdf>

Hair, JF; Anderson, RE; Tatham, RL; Black, WC. 1999. Análisis Multivariante. 5 ed. Madrid, España. Prentice Hall Iberia.p.93,105,106,612-614,618,620,622-623,626,628,630-633,635-637,640,671-672,679-684.

Hoyle, RH. 1995. Structural Equation Modeling. United States of America. Sage Publications, Inc. p.1.

Kline, RB. 2016. Principles and Practice of Structural Equation Modeling. 4 ed. New York, London. Guilford Publications, Inc. p.10,272

Lescano Albán, E. 2002. Interacción entre el desempeño docente y las condiciones de estudio sobre el rendimiento académico de los estudiantes de la Universidad Nacional de Piura (en línea). Piura, Perú. p.4. Consultado el 27 set 2018. Disponible en <http://www.unp.edu.pe/institutos/iipd/trabajosinvestigacion/MEDICINAHUMANA-EDALESCANO.doc>

Luque Martínez, T. 2000. Técnicas de análisis de datos en investigación de mercados. Madrid, España. Ediciones Pirámide. p. 520.

Malhotra, NK. 2004. Investigación de Mercados.4 ed. México. Pearson Education. p. 269

Monrroy Almonte, M. 2012. Desempeño docente y rendimiento académico en matemática de los alumnos de una institución educativa de Ventanilla – Callao (en línea). Tesis Maestro. Callao, Perú. USIL. p.12. Consultado el 13 set. 2018. Disponible en http://repositorio.usil.edu.pe/bitstream/123456789/1220/1/2012_Monrroy_Desempe%C3%B1o%20docente%20y%20rendimiento%20acad%C3%A9mico%20en%20matem%C3%A1tica%20de%20los%20alumnos%20de%20una%20instituci%C3%B3n%20educativa%20de%20Ventanilla-Callao.pdf

Muelas Plaza, A. 2013. Influencia de la variable de personalidad en el rendimiento académico de los estudiantes cuando finalizan la Educación Secundaria Obligatoria (ESO) y comienzan Bachillerato (en línea). Universidad Internacional de la Rioja. Historia y Comunicación Social Vol. 18. N° Esp. Nov. (2013). p.121,123. Consultado el 17 dic 2018. Disponible en <http://revistas.ucm.es/index.php/HICS/article/viewFile/44230/41792>

Navajas Seco, R. 2016. La mejora del autoconcepto en estudiantes universitarios a través de un programa expresivo-corporal (en línea). Tesis Doctora. Madrid, España. Universidad Complutense de Madrid. p.33. Consultado el 27 de octubre del 2018. Disponible en <https://eprints.ucm.es/40413/1/T38104.pdf>

Palomino Zamudio, FC. 2012. El desempeño docente y el aprendizaje de los estudiantes de la Unidad Académica de Estudios Generales de la Universidad de San Martín de Porres (en línea). Tesis Magíster en Educación. Lima, Perú. UNMSM. p.31,59. Consultado el 14 oct. 2018. Disponible en http://cybertesis.unmsm.edu.pe/bitstream/handle/cybertesis/1693/Palomino_zf.pdf?sequence=1&isAllowed=y

Quintero, V; Zárate, N. 2016. Autoestima, autoconcepto y su relación con el rendimiento académico en estudiantes de odontología (en línea). Revista de Sistemas y Gestión Educativa. p.13. Consultado el 26 oct 2018. Disponible en http://www.ecorfan.org/bolivia/researchjournals/Sistemas_y_Gestion_Educativa/vol3num9/Sistemas_y_Gestion_Educativa_V3_N9_2.pdf

Reyes Manrique, ME. 2016. Relación entre Habilidades Sociales y Desempeño Docente desde la percepción de estudiantes adultos de universidad privada en Lima, Perú (en línea). Lima, Perú. Rev. Digit. Invest. Docencia Univ. vol.10 no.2. Consultado el 26 set. 2018. Disponible en http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S2223-25162016000200003

Rodríguez Ayán, MN. 2007. Análisis multivariado del desempeño académico de estudiantes universitarios de Química (en línea). Tesis Doctoral. Madrid, España. Universidad Autónoma de Madrid. p.57,60. Consultado el 24 oct. 2018. Disponible en https://repositorio.uam.es/bitstream/handle/10486/1800/5491_rodriguez_ayan.pdf

Rosseel Y. 2012. lavaan: An R Package for Structural Equation Modeling (en línea). Ghent University. May 2012, Volume 48, Issue 2. p.27-28. Consultado 02 dic 2018. Disponible en <https://www.jstatsoft.org/index.php/jss/article/view/v048i02/v48i02.pdf>

Swe Khine, M. 2013. Application of Structural Equation Modeling in Educational Research and Practice. Perth, Australia. Sense Publishers.p.4.

Schumacker, RE; Lomax, RG. 2016. A Beginner's Guide to Structural Equation Modeling. 4 ed. New York. Routledge.p.1-2,19-20,38-39,93,108,113.

Tornimbeni, S; Pérez, E; Olaz, F. 2008. Introducción a la Psicometría (en línea). Buenos Aires, Argentina. Consultado el 11 de abr. del 2019. Disponible en https://www.academia.edu/29103759/INTRODUCCI%C3%93N_A_LA_PSICOMETR%C3%8DA

Veliz Burgos, A; Apodaca Urquijo, P. 2012. Niveles de autoconcepto, autoeficacia académica y bienestar psicológico en estudiantes universitarios de la ciudad de temuco (En Línea). Temuco, Chile. Universidad Mayor Sede Temuco. Salud & Sociedad, V.3, N°.2. p.132. Consultado el 05 ene 2019. Disponible en <https://dialnet.unirioja.es/servlet/articulo?codigo=3993052>

Véliz Capuñay, C. 2017. Análisis multivariante. 1 ed. Lima, Perú, Cengage Learning.p.155-156,158,165,166-167,170-171,173, 174.

Weiers, RM. 1986. Investigación de Mercados. México. Prentice- Hall Hispanoamericana, S.A.p.155,156.

VIII. ANEXOS

Anexo 1: Encuesta docente

Marque con un círculo la cuadrícula con el número que a su juicio represente el calificativo más apropiado. En la escala los extremos representan: **1 “Muy bajo”** y **10 “Muy alto”**.

En qué medida el **Profesor de teoría del curso**:

P₁: Demuestra interés por los alumnos que tienen problemas en aprender, al ritmo de la clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂: Motiva a que participemos crítica y activamente en el desarrollo de la clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₃: Explica la calificación y es capaz de revisarla si considera que puede haber error

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₄: Realiza un resumen del tema anterior, al inicio de cada clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₅: Explica de manera clara y ordenada

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₆: Utiliza las nuevas tecnologías de información (aula virtual, internet, video conferencias, etc.)

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₇: Evidencia haber preparado sus clases con la debida anticipación

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₈: Resume y enfatiza las ideas claves de cada tema de clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₉: Relaciona adecuadamente la teoría con la práctica utilizando aplicaciones reales

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₀: Demuestra dominio sobre el curso que imparte

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₁: Utiliza adecuadamente los recursos didácticos del aula (pizarra, multimedia, Tv, etc.)

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₂: Utiliza métodos de instrucción diversos (trabajo grupal, lecturas, casos, exposiciones, etc.)

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₃: Elabora y/o utiliza materiales de estudio como: notas de clase, separatas, guías, libros, etc.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₄: Termina la clase a la hora que corresponde

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₅: Se encuentra disponible en el horario que estableció para horas de consultas extra clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₆: Plantea al inicio de cada sesión de clase, objetivos claros y concisos

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₇: Asiste normalmente a clase, justifica con anticipación su falta y la recupera con prontitud

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₈: Desarrolla ordenadamente todos los objetivos planteados al inicio de clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₁₉: Desarrolla los contenidos del programa del curso en forma interesante y amena

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₀: Inicia la clase a la hora que corresponde

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₁: Elabora evaluaciones cuyo nivel se corresponde con el de las clases

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₂: Mantiene su entusiasmo y dinamismo durante toda la sesión de clase

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₃: Logro satisfacer mis expectativas y volvería a llevar un curso con él

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₄: Es justo e imparcial a la hora de evaluar y calificar

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

P₂₅: Realiza evaluaciones periódicas a lo largo del ciclo

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

Anexo 2: Encuesta de autoconcepto estudiantil

A continuación encontrará una serie de situaciones vivenciales. Lea cuidadosamente y conteste marcando con un círculo de acuerdo a su nivel de identificación con cada una de ellas, en una escala del 1 al 10, donde **1=poco identificado** y **10= muy identificado**.

1. Hago bien los trabajos en la universidad.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

2. Hago fácilmente amigos

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

3. Tengo miedo de algunas cosas

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

4. Recibo críticas en mi entorno familiar

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

5. Me siento seguro(a) cuando se trata de participar en actividades deportivas

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

6. Mis profesores me consideran un buen estudiante

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

7. Soy una persona amigable

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

8. Muchas cosas me ponen nervioso

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

9. Me siento feliz en casa

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

10. Me buscan para realizar actividades deportivas

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

11. Trabajo mucho en clase.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

12. Tengo dificultades para hacer amigos con facilidad.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

13. Me asusto con facilidad

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

14. Mi familia está decepcionada de mi

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

15. Practico deporte para mejorar mi apariencia personal

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

16. Mis profesores me estiman

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

17. Soy una persona alegre

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

18. Cuando los mayores me dicen algo me pongo muy nervioso

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

19. Mi familia me ayudaría en cualquier tipo de problemas

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

20. Considero que siempre soy de los(las) mejores cuando se trata de participar en actividades deportivas.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

21. Soy un buen estudiante

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

22. Tengo dificultades para interrelacionarme con personas desconocidas

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

23. Me pongo nervioso cuando me pregunta el profesor

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

24. Mis padres me dan confianza

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

25. Soy bueno haciendo deporte

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

26. Mis profesores me consideran inteligente y trabajador

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

27. Tengo muchos amigos

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

28. Me siento nervioso

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

29. Me siento querido por mis padres

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

30. Cuando surge la oportunidad, siempre soy de los(las) primeros(as) para participar en deportes.

1	2	3	4	5	6	7	8	9	10
---	---	---	---	---	---	---	---	---	----

Anexo 3: Códigos utilizados

```
install.packages("psych")
install.packages("multilevel")
install.packages("semPlot")
install.packages("GPArotation")
install.packages("MVN")
install.packages("lavaan")
install.packages("mice")
install.packages("BaylorEdPsych")

library(psych)
library(multilevel)
library(semPlot)
library("GPArotation")
library(MVN)
library(lavaan)
library(mice)
library(BaylorEdPsych)

#Para leer los datos de los registros de notas y códigos.

lectura_excel <- function(encabezado=TRUE,...) {
read.table("clipboard", sep="\t", header=encabezado,...)
}

archivo_notas_códigos<-lectura_excel()

str(archivo_notas_códigos)

archivo_notas_códigos$Código=as.character(archivo_notas_códigos$Código)
archivo_notas_códigos$Alumno=as.character(archivo_notas_códigos$Alumno)
```

```

#Para leer los datos de las encuestas y códigos.
lectura_excel <- function(encabezado=TRUE,...) {
read.table("clipboard",sep="\t",header=encabezado,...)
}

archivo_encuestas_códigos<-lectura_excel()

str(archivo_encuestas_códigos)

archivo_encuestas_códigos$Código=as.character(archivo_encuest
as_códigos$Código)

str(archivo_encuestas_códigos)

juntar1=merge(archivo_notas_códigos,archivo_encuestas_códigos
,by="Código",all=F)

juntar2=juntar1[order(juntar1$Alumno),]

#Para ver la cantidad de registros
dim(juntar2)

# Generación de índices
set.seed(20)
índices=sample(1:nrow(juntar2),338,F)
índices

#Muestra para el análisis
muestral=juntar2[índices,]

dim(muestral)

datostesis=muestral

```



```

dim(datostesis)

sum(complete.cases(datostesis))

datostesis1=datostesis

#Separación en bloques para hacer la imputación multivariada

bloque1=datostesis1[,1:6]
names(bloque1)

# De la encuesta docente
bloque2=datostesis1[,7:31]
names(bloque2)

bloque3=datostesis1[,32:61]
names(bloque3)

LittleMCAR(bloque2)$p.value
LittleMCAR(bloque3)$p.value

bloque2_imp=mice(bloque2,m=1, meth='pmm', seed=100)
bloque2_imp1=complete(bloque2_imp,1)

bloque3_imp=mice(bloque3,m=1, meth='pmm', seed=100)
bloque3_imp1=complete(bloque3_imp,1)

docente=bloque2_imp1
names(docente)

autoconcepto=bloque3_imp1
names(autoconcepto)
autoconceptof=autoconcepto

```

```
autoconceptof$a4=10-autoconceptof$a4
autoconceptof$a12=10-autoconceptof$a12
autoconceptof$a14=10-autoconceptof$a14
autoconceptof$a22=10-autoconceptof$a22
```

```
factorial_autoconcepto=principal(cor(autoconceptof),nfactors=
5,rotate="oblimin")
```

```
factorial_autoconcepto$loadings
```

```
cronbach(autoconceptof)
```

```
a1=autoconceptof[,1]
a2=autoconceptof[,2]
a3=autoconceptof[,3]
a4=autoconceptof[,4]
a5=autoconceptof[,5]
a6=autoconceptof[,6]
a7=autoconceptof[,7]
a8=autoconceptof[,8]
a9=autoconceptof[,9]
a10=autoconceptof[,10]
a11=autoconceptof[,11]
a12=autoconceptof[,12]
a13=autoconceptof[,13]
a14=autoconceptof[,14]
a15=autoconceptof[,15]
a16=autoconceptof[,16]
a17=autoconceptof[,17]
a18=autoconceptof[,18]
a19=autoconceptof[,19]
a20=autoconceptof[,20]
a21=autoconceptof[,21]
a22=autoconceptof[,22]
```

```
a23=autoconceptof[,23]
a24=autoconceptof[,24]
a25=autoconceptof[,25]
a26=autoconceptof[,26]
a27=autoconceptof[,27]
a28=autoconceptof[,28]
a29=autoconceptof[,29]
a30=autoconceptof[,30]
```

```
docente1=docente[,-23]
names(docente1)
```

```
factorial_docente=principal(cor(docente1),nfactors=6,rotate="
varimax")
```

```
factorial_docente$loadings
```

```
cronbach(docente1)
```

```
d1=docente1[,1]
d2=docente1[,2]
d3=docente1[,3]
d4=docente1[,4]
d5=docente1[,5]
d6=docente1[,6]
d7=docente1[,7]
d8=docente1[,8]
d9=docente1[,9]
d10=docente1[,10]
d11=docente1[,11]
d12=docente1[,12]
d13=docente1[,13]
d14=docente1[,14]
d15=docente1[,15]
```

```

d16=docente1[,16]
d17=docente1[,17]
d18=docente1[,18]
d19=docente1[,19]
d20=docente1[,20]
d21=docente1[,21]
d22=docente1[,22]
d24=docente1[,23]
d25=docente1[,24]

planificacion=rowSums(cbind(d16,d18,d4,d7))/4
dominio_curso=rowSums(cbind(d5,d8,d9,d10))/4
metodos_recurso=rowSums(cbind(d6,d12,d11,d13))/4
cumplimiento=rowSums(cbind(d14,d15,d17,d20))/4
metodo_evaluativo=rowSums(cbind(d3,d21,d24,d25))/4
motivacion_interaccion=rowSums(cbind(d1,d2,d19,d22))/4

academico=(rowSums(cbind(a1,a6,a11,a16,a21,a26)))/6
social=(rowSums(cbind(a2,a7,a12,a17,a22,a27)))/6
emocional=(rowSums(cbind(a3,a8,a13,a18,a23,a28)))/6
familiar=(rowSums(cbind(a4,a9,a14,a19,a24,a29)))/6
fisico=(rowSums(cbind(a5,a10,a15,a20,a25,a30)))/6

notacurso=bloque1[,4]
prom_pond_ac=bloque1[,5]
prom_pond_ac

modelo1<-"
d_docente=~planificacion+dominio_curso+metodos_recurso+cumpl
imiento+metodo_evaluativo+motivacion_interaccion
d_autoconcepto=~academico+social+emocional+familiar+fisico
rendimiento_curso=~notacurso
rendimiento_pasado=~prom_pond_ac
rendimiento_curso~d_docente+d_autoconcepto+rendimiento_pasado

```

```

d_autoconcepto~d_docente
"

datosc=data.frame(planificacion,dominio_curso,metodo_evaluati
vo,cumplimiento,motivacion_interaccion,metodos_recursos,acade
mico,social,emocional,familiar,fisico,notacurso,prom_pond_ac)

dim(datosc)

#Prueba de normalidad multivariada
pruebal=mvn(data = datosc, mvnTest = "hz")
pruebal$multivariateNormality

sem_modelo1<-
sem(modelo1,estimator="MLM",data=datosc,std.lv=T)

sem_modelo1<- sem(modelo1,se="robust",test
="Satorra.Bentler",data=datosc,std.lv=T)

resultados1<-
summary(sem_modelo1,standardized=TRUE,fit.measures = TRUE)

##Medidas de ajuste absoluto GFI, RMSEA y SRMR.

resultados2=fitMeasures(sem_modelo1)

resultados2["gfi"]

resultados2["rmsea.robust"]

##Medidas de ajuste incremental TLI, CFI y AGFI.

resultados2["cfi.robust"]
resultados2["tli.robust"]

```

```

resultados2["agfi"]

##Medidas de ajuste de parsimonia PGFI y PNFI

resultados2["pgfi"]
resultados2["pnfi"]

semPaths(sem_modelo1,what="std",edge.label.cex=1.0,
curvePivot = TRUE,nodeLabels=c("Planificación \n del curso",
"Dominio del \n curso","Metodos y \n recursos","Cumplimiento
de \n obligaciones","Método \n evaluativo","Motivación e \n
interacción",
"Académico","Social","Emocional","Familiar","Físico","Nota
del \n curso",
"Promedio \n ponderado","Desempeño \n
docente","Autoconcepto","Rendimiento \n académico",
"Rendimiento \n pasado"),
fade=FALSE,style="lisrel",sizeMan=9,sizeMan2=5,label.cex=1.1,
sizeLat=13,sizeLat2=6)

indicesm=modindices(sem_modelo1,sort=TRUE)[,1:5]

dim(indicesm)

modindices(sem_modelo1,sort=TRUE,minimum.value=3.84)[,1:5]

modelo2<-"
d_docente=~planificacion+dominio_curso+metodos_recursos+cumpl
imiento+metodo_evaluativo+motivacion_interaccion
d_autoconcepto=~academico+social+emocional+familiar+fisico
rendimiento_curso=~notacurso
rendimiento_pasado=~prom_pond_ac
rendimiento_curso~d_docente+d_autoconcepto+rendimiento_pasado
d_autoconcepto~d_docente

```

```

d_autoconcepto~rendimiento_pasado
"

sem_modelo2<-
sem(modelo2,estimator="MLM",data=datosc,std.lv=T)

sem_modelo2<- sem(modelo2,se="robust",test
="Satorra.Bentler",data=datosc,std.lv=T)

resultados3<-
summary(sem_modelo2,standardized=TRUE,fit.measures = TRUE)

##Medidas de ajuste absoluto GFI, RMSEA y SRMR.

resultados4=fitMeasures(sem_modelo2)

resultados4["gfi"]

resultados4["rmsea.robust"]

##Medidas de ajuste incremental CFI, TLI y AGFI.

resultados4["cfi.robust"]
resultados4["tli.robust"]
resultados4["agfi"]

##Medidas de ajuste de parsimonia PGFI y PNFI

resultados4["pgfi"]
resultados4["pnfi"]

semPaths(sem_modelo2,what="std",edge.label.cex=1.0,
curvePivot = TRUE,nodeLabels=c("Planificación \n del curso",

```

```
"Dominio del \n curso", "Metodos y \n recursos", "Cumplimiento
de \n obligaciones", "Método \n evaluativo", "Motivación e \n
interacción",
"Académico", "Social", "Emocional", "Familiar", "Físico", "Nota
del \n curso",
"Promedio \n ponderado", "Desempeño \n
docente", "Autoconcepto", "Rendimiento \n académico",
"Rendimiento \n pasado"),
fade=FALSE, style="lisrel", sizeMan=9, sizeMan2=5, label.cex=1.1,
sizeLat=13, sizeLat2=6, edge.label.position=0.66)
```


Anexo 4: Tabla completa de las relaciones y sus índices de modificación

	lhs	op	rhs	mi	epc
69	rendimiento_pasado	=~	academico	51.044	0.432
57	rendimiento_curso	=~	academico	49.342	0.377
36	d_docente	=~	academico	24.106	0.452
61	rendimiento_curso	=~	fisico	22.927	-0.439
73	rendimiento_pasado	=~	fisico	22.314	-0.537
137	academico	~~	prom_pond_ac	17.884	0.358
133	academico	~~	emocional	15.308	0.503
138	social	~~	emocional	14.840	-0.535
37	d_docente	=~	social	14.810	-0.371
62	rendimiento_curso	=~	prom_pond_ac	14.424	100.672
159	d_autoconcepto	~	rendimiento_pasado	14.354	0.263
50	d_autoconcepto	=~	prom_pond_ac	14.354	0.428
156	d_autoconcepto	~~	rendimiento_pasado	14.354	0.256
164	rendimiento_pasado	~	d_autoconcepto	14.354	0.256
158	d_autoconcepto	~	rendimiento_curso	14.354	0.358
153	d_docente	~~	d_autoconcepto	14.353	-1.536
161	d_docente	~	d_autoconcepto	14.352	-1.536
163	rendimiento_pasado	~	rendimiento_curso	14.288	59.842
160	d_docente	~	rendimiento_curso	14.140	-357.438
108	cumplimiento	~~	metodo_evaluativo	9.855	0.171
70	rendimiento_pasado	=~	social	9.780	-0.242
58	rendimiento_curso	=~	social	9.772	-0.197
47	d_autoconcepto	=~	metodo_evaluativo	8.217	0.198
66	rendimiento_pasado	=~	cumplimiento	8.190	-0.153
89	dominio_curso	~~	metodo_evaluativo	8.180	-0.118
38	d_docente	=~	emocional	8.151	0.312
90	dominio_curso	~~	motivacion_interaccion	8.034	0.110
136	academico	~~	notacurso	7.803	0.594
54	rendimiento_curso	=~	cumplimiento	7.772	-0.119
123	metodo_evaluativo	~~	notacurso	7.513	0.449
118	metodo_evaluativo	~~	academico	6.923	0.159
92	dominio_curso	~~	social	6.834	-0.137
150	fisico	~~	notacurso	6.004	-0.839
122	metodo_evaluativo	~~	fisico	5.812	-0.275
88	dominio_curso	~~	cumplimiento	5.731	-0.093
151	fisico	~~	prom_pond_ac	5.715	-0.364
79	planificacion	~~	motivacion_interaccion	5.706	-0.106
55	rendimiento_curso	=~	metodo_evaluativo	4.505	0.095
72	rendimiento_pasado	=~	familiar	4.425	0.143
144	emocional	~~	fisico	4.287	-0.409
110	cumplimiento	~~	academico	4.201	-0.119
140	social	~~	fisico	3.832	0.344
149	familiar	~~	prom_pond_ac	3.766	0.178
129	motivacion_interaccion	~~	fisico	3.337	0.183
147	familiar	~~	fisico	3.101	-0.272
124	metodo_evaluativo	~~	prom_pond_ac	3.081	-0.129
82	planificacion	~~	emocional	3.050	0.129
143	emocional	~~	familiar	2.769	-0.203
75	planificacion	~~	dominio_curso	2.703	0.062
117	metodo_evaluativo	~~	motivacion_interaccion	2.681	-0.084
44	d_autoconcepto	=~	dominio_curso	2.562	-0.076

<<continuación>>

64	rendimiento_pasado	==	dominio_curso	2.542	0.061
111	cumplimiento	~~	social	2.540	0.119
128	motivacion_interaccion	~~	familiar	2.512	-0.095
78	planificacion	~~	metodo_evaluativo	2.427	0.075
119	metodo_evaluativo	~~	social	2.355	0.119
116	cumplimiento	~~	prom_pond_ac	2.295	-0.107
142	social	~~	prom_pond_ac	2.052	-0.149
83	planificacion	~~	familiar	2.001	0.077
114	cumplimiento	~~	fisico	1.962	0.153
59	rendimiento_curso	==	emocional	1.942	0.103
107	metodos_recurso	~~	prom_pond_ac	1.897	0.097
115	cumplimiento	~~	notacurso	1.869	-0.215
97	dominio_curso	~~	prom_pond_ac	1.659	0.064
127	motivacion_interaccion	~~	emocional	1.646	0.104
141	social	~~	notacurso	1.632	-0.303
71	rendimiento_pasado	==	emocional	1.568	0.116
104	metodos_recurso	~~	familiar	1.474	-0.079
106	metodos_recurso	~~	notacurso	1.190	-0.171
105	metodos_recurso	~~	fisico	1.185	0.119
132	academico	~~	social	0.995	-0.144
60	rendimiento_curso	==	familiar	0.988	0.055
126	motivacion_interaccion	~~	social	0.964	-0.067
52	rendimiento_curso	==	dominio_curso	0.873	0.028
65	rendimiento_pasado	==	metodos_recurso	0.832	0.049
63	rendimiento_pasado	==	planificacion	0.748	-0.039
109	cumplimiento	~~	motivacion_interaccion	0.734	0.042
48	d_autoconcepto	==	motivacion_interaccion	0.723	-0.052
84	planificacion	~~	fisico	0.656	-0.074
135	academico	~~	fisico	0.582	-0.130
51	rendimiento_curso	==	planificacion	0.537	-0.026
93	dominio_curso	~~	emocional	0.520	-0.045
40	d_docente	==	fisico	0.449	-0.091
80	planificacion	~~	academico	0.413	0.031
145	emocional	~~	notacurso	0.347	0.163
76	planificacion	~~	metodos_recurso	0.303	-0.025
86	planificacion	~~	prom_pond_ac	0.288	-0.032
95	dominio_curso	~~	fisico	0.234	-0.037
120	metodo_evaluativo	~~	emocional	0.227	-0.044
100	metodos_recurso	~~	motivacion_interaccion	0.226	0.023
125	motivacion_interaccion	~~	academico	0.197	0.024
134	academico	~~	familiar	0.152	0.049
68	rendimiento_pasado	==	motivacion_interaccion	0.129	-0.018
81	planificacion	~~	social	0.129	-0.022
146	emocional	~~	prom_pond_ac	0.127	0.044
53	rendimiento_curso	==	metodos_recurso	0.123	-0.015
148	familiar	~~	notacurso	0.107	-0.069
45	d_autoconcepto	==	metodos_recurso	0.096	-0.020
43	d_autoconcepto	==	planificacion	0.094	0.017
113	cumplimiento	~~	familiar	0.088	0.019
131	motivacion_interaccion	~~	prom_pond_ac	0.082	-0.019
121	metodo_evaluativo	~~	familiar	0.079	0.019
85	planificacion	~~	notacurso	0.077	-0.037
77	planificacion	~~	cumplimiento	0.075	-0.012
102	metodos_recurso	~~	social	0.066	-0.019
46	d_autoconcepto	==	cumplimiento	0.064	-0.017
112	cumplimiento	~~	emocional	0.055	0.021
56	rendimiento_curso	==	motivacion_interaccion	0.049	-0.009

<<continuación>>

103	metodos_recurso	~~	emocional	0.038	-0.017
98	metodos_recurso	~~	cumplimiento	0.035	0.010
67	rendimiento_pasado	=~	metodo_evaluativo	0.034	-0.010
94	dominio_curso	~~	familiar	0.034	0.008
99	metodos_recurso	~~	metodo_evaluativo	0.021	-0.008
87	dominio_curso	~~	metodos_recurso	0.018	0.005
39	d_docente	=~	familiar	0.011	-0.009
101	metodos_recurso	~~	academico	0.006	0.004
91	dominio_curso	~~	academico	0.002	-0.002
139	social	~~	familiar	0.000	-0.002
130	motivacion_interaccion	~~	notacurso	0.000	-0.001
96	dominio_curso	~~	notacurso	0.000	0.000