

Comparación de métodos estructurales para la caracterización de factores latentes en la escala de autoestima de Rosenberg

Comparison of structural methods for the characterization of latent factors in the Rosenberg self-esteem scale



Jeanett López García*

Universidad Nacional Autónoma de México, FES Acatlán

Jorge Javier Jiménez Zamudio**

Universidad Nacional Autónoma de México, FES Acatlán

https://doi.org/10.36105/pedag_infinita.2026v1n2.09

Resumen

En la investigación asociada a la psicometría y a las ciencias de la educación, la caracterización precisa de factores latentes es fundamental para comprender constructos como la autoestima, la motivación o la satisfacción. En este contexto, la escala de autoestima de Rosenberg es una de las más conocidas para medir este constructo psicológico. Entre los métodos estructurales empleados para analizar factores latentes se encuentran el Análisis Factorial, el Análisis de Componentes Principales,

* Correo electrónico: jeanettlg@comunidad.unam.mx <https://orcid.org/0000-0002-0071-6864>

** Correo electrónico: jijz_02@comunidad.unam.mx <https://orcid.org/0000-0002-2699-8740>

Recepción: 11/03/2026 Aceptación: 21/05/2026

CÓMO CITAR: López García, J., Jiménez Zamudio, J. J. (2026). Comparación de métodos estructurales para la caracterización de factores latentes en la escala de autoestima de Rosenberg. *Pedagogía infinita*, vol. 1, núm. 2, 174-191. DOI: https://doi.org/10.36105/pedag_infinita.2026v1n2.09



el Análisis Paralelo y, más recientemente, los autocodificadores de redes neuronales. Cada uno de estos métodos aporta un tipo específico de información sobre la dimensionalidad y la estructura subyacente de los datos, lo que impacta directamente en las interpretaciones sobre el constructo. El Análisis Factorial, por ejemplo, se centra en identificar factores comunes a través de correlaciones entre ítems, mientras que el Análisis de Componentes Principales simplifica la variabilidad en componentes principales. Por su parte, el Análisis Paralelo ayuda a determinar el número adecuado de factores o componentes, y los autocodificadores, como técnica moderna de redes neuronales, ofrecen una perspectiva no lineal que permite una representación más compleja de los datos. Dado el papel esencial de estos métodos en la investigación y la práctica, este estudio se propone determinar los diferentes tipos de información que proporcionan estos métodos estructurales en la caracterización de los factores latentes de la escala de autoestima de Rosenberg. Con ello, se pretende contribuir a una comprensión más integral de cómo cada técnica estructura y representa los datos, y a la identificación de sus posibles aplicaciones y limitaciones en el análisis de constructos psicológicos complejos.

Palabras clave: métodos estructurales, escala, autoestima, análisis factorial, factores latentes.

Abstract

In research associated with psychometrics and educational sciences, the precise characterization of latent factors is essential to understand constructs such as self-esteem, motivation or satisfaction. In this context, the Rosenberg self-esteem scale is one of the best known to measure this psychological construct. Among the structural methods used to analyze latent factors are Factor Analysis, Principal Component Analysis, Parallel Analysis and, more recently, neural network autoencoders. Each of these methods provides a specific type of information about the dimensionality and underlying structure of the data, which directly impacts interpretations of the construct. Factor Analysis, for example, focuses on identifying common factors through correlations between items, while Principal Components Analysis simplifies variability into principal components. For its part, Parallel Analysis helps determine the

appropriate number of factors or components, and autoencoders, as a modern neural network technique, offer a non-linear perspective that allows a more complex representation of the data. Given the essential role of these methods in research and practice, this study aims to determine the different types of information that these structural methods provide in the characterization of the latent factors of the Rosenberg self-esteem scale. The aim is to contribute to a more comprehensive understanding of how each technique structures and represents data, and to the identification of its possible applications and limitations in the analysis of complex psychological constructs.

Keywords: structural methods, scale, self-esteem, factor analysis, latent factors.

Introducción

En principio, las ciencias como la biología, sociología, psicología y la educación, requieren de evidencia empírica basada en la observación cuidadosa; para ello los investigadores cuentan con una variedad de métodos para la recolección de tales evidencias empíricas, y entre ellos se encuentran las encuestas, en donde se plantea una serie de preguntas predeterminadas y validadas a través de cuestionarios, mismos, que permiten recoger información sin modificar o influir en el entorno (Jhangiani *et al.*, 2019).

Si bien los cuestionarios permiten recoger un gran número de variables de forma simultánea, el investigador precisa de analizar la estructura latente de los datos y entender las relaciones entre variables observadas o si las preguntas del cuestionario se agrupan de alguna forma característica que lo pueda llevar a encontrar grupos de variables con significado común; para ello, se pueden utilizar en investigación el Análisis Factorial (AF) o el método de Análisis de Componentes Principales (ACP), que son técnicas clásicas de estadística multivariada¹, que analizan simultáneamente múltiples variables para identificar patrones en los datos; o el Método Paralelo (MP) que en sí mismo no es un método de análisis multivariado², pero que sí es un procedimiento estadístico diseñado para evaluar la dimensionalidad de los

1 La estadística multivariada analiza simultáneamente múltiples variables y busca identificar patrones, reducir dimensiones o modelar relaciones de dependencia/interdependencia.

2 El método Paralelo no pertenece a la estadística multivariada dado que no analiza simultáneamente múltiples variables, así como tampoco establece relaciones entre variables

datos y decidir cuántos factores o componentes deben retenerse en análisis como el AF o el ACP. Entre los métodos estructurales empleados recientemente para analizar factores latentes se encuentran los autocodificadores de redes neuronales, una técnica novedosa que permite identificar espacios latentes mucho más flexibles y poderosos, garantizando así que sea más compacto que el espacio de datos.

Si bien la estructura factorial de la Escala de Autoestima de Rosenberg ha sido ampliamente investigada, los hallazgos no son concluyentes. Algunos estudios han encontrado un modelo de un solo factor (Martín-Albó et al., 2007), mientras que otros han propuesto estructuras de dos o tres factores (De la Fuente, 2011). Dada la falta de consenso en la literatura, es relevante profundizar en el análisis comparativo de los diferentes métodos estructurales utilizados para caracterizar los factores latentes en la Escala de Autoestima de Rosenberg, a fin de contribuir a una mejor comprensión de la estructura interna de este instrumento (Martín-Albó et al., 2007; De la Fuente, 2011; Jiménez et al., 2018).

La investigación en torno a la Escala de Autoestima de Rosenberg se ha centrado en examinar su estructura factorial subyacente mediante el empleo de diversos enfoques analíticos, tales como el AF Confirmatorio, el ACP y el Análisis Paralelo (Davis et al., 2009; Jiménez et al., 2018). En contraste, se podría hacer uso de autocodificadores de las redes neuronales, ya que estos modelos de aprendizaje profundo tienen la capacidad de extraer características latentes de manera más flexible y adaptativa, sin estar sujetos a supuestos tan restrictivos como los análisis factoriales tradicionales (Tafarodi y Swann, 1995).

Es así, que el objetivo del presente trabajo es determinar los tipos de información que aportan los métodos estructurales —AF, ACP, Método Paralelo y Autocodificadores— para caracterizar los factores latentes en la escala de autoestima de Rosenberg.

Antecedentes teóricos

Análisis factorial (AF)

Es una técnica del análisis multivariado que persigue reducir la dimensión de una tabla de datos que contiene un elevado número de variables de carácter

cuantitativo y aspira a quedarse con unas cuantas variables ficticias que, aunque no observadas, sean combinación de las reales y sinteticen la mayor parte de la información contenida en sus datos (Pérez, 2004, p.112).

El AF es una técnica de reducción de datos, a partir de un conjunto numeroso de variables; sirve para encontrar grupos homogéneos de variables que se integran con las variables que correlacionen mucho entre sí y pretendiendo, inicialmente, que unos grupos sean independientes de otros. El AF, a partir de operar una matriz de correlaciones (opera con correlaciones elevadas al cuadrado, es decir, r^2), intenta simplificar la información que ofrece; analiza la varianza común a todas las variables. Cada elemento de la matriz de correlaciones (cruce de la una fila y una columna del arreglo matricial) expresa la proporción de varianza común a dos ítems o variables, es decir, es la varianza que cada ítem o variable comparte con los demás, excepto en la diagonal principal³ (De la Fuente, 2011).

Análisis de componentes principales

Es una técnica multivariada de interdependencia orientada a la reducción de dimensionalidad. Se aplica cuando se desea resumir la información contenida en un conjunto amplio de variables métricas correlacionadas, sin establecer distinción entre variables dependientes e independientes. Este procedimiento busca transformar las variables originales en un número menor de componentes que conserven la mayor proporción posible de la varianza total observada en los datos. Así, el ACP debe distinguirse del análisis factorial, ya que este último busca identificar factores latentes que expliquen las relaciones entre variables, mientras que el ACP construye componentes estadísticos derivados de combinaciones lineales de las variables originales (Bech, 2019; Schreiber, 2021).

Los componentes principales se ordenan de acuerdo con la proporción de varianza que explican. Así, el primer componente captura la mayor cantidad posible de varianza total; el segundo, captura la mayor varianza restante, con la restricción de ser ortogonal, es decir, no correlacionado, respecto del primero; y así sucesivamente. Desde esta perspectiva, el ACP permite

³ El elemento de la diagonal siempre toma el valor de 1 dado expresa la correlación donde cada ítem coincide consigo mismo.

representar un conjunto amplio de variables mediante un número menor de componentes, facilitando la descripción de patrones de asociación y la interpretación sintética de la estructura de los datos (Jolliffe y Cadima, 2016).

Varianza

El término varianza se refiere a la cantidad de información o dispersión que existe en los datos y cómo ésta es explicada por los factores o componentes extraídos. La varianza " σ^2 " es el promedio de las distancias al cuadrado que van desde las observaciones como la media, y la desviación estándar que es la raíz cuadrada de la varianza, es decir " σ ". En un cuestionario o escala, cada ítem o variable tiene su varianza y ella indica la diferencia que crea en las respuestas de los individuos (los encuestados).

Los tipos de varianza son: (i) varianza común o compartida (comunalidad, h^2) que es la parte de la varianza de una variable que puede explicarse por los factores extraídos; esta varianza compartida es la que genera la correlación entre los ítems, así, si dos o más ítems miden aspectos similares de un fenómeno, la parte de su varianza que es común se reflejará en la correlación observada entre ellos. (ii) varianza específica (σ^2) que corresponde a la parte de la varianza de una variable que es única y no compartida con otras variables. (iii) varianza error (e^2) que corresponde al ruido o imprecisiones en la medición. (iv) varianza total que corresponde a la suma de la varianza explicada por los factores, la varianza específica y la varianza error.

En AF se intenta separar la varianza de cada ítem en dos partes: la varianza común (comunalidad) que corresponde a la parte compartida entre ítems, atribuible a factores latentes y la varianza específica (incluyendo error). La parte única a cada ítem, no explicada por los factores comunes.

En ACP toda la varianza es considerada explicativa (sin distinguir errores) y el procedimiento es diferente. Se utiliza la descomposición en valores propios o, alternativamente, la descomposición en valores singulares (SVD) de la matriz de covarianzas (o de correlaciones). Cada componente principal se asocia a un eigenvalor, el cual indica cuánta de la varianza total de los datos explica ese componente. La suma de todos los eigenvalores equivale a la varianza total de los datos.

En el contexto del ACP, la descomposición en valores singulares SVD se utiliza para identificar las direcciones en las que los datos varían más (los

componentes principales) y cuantificar esa variabilidad a través de los valores singulares.

Análisis paralelo (AP)

También conocido como análisis paralelo de Horn.⁴ Es un método estadístico utilizado para determinar el número de componentes a mantener en un análisis de factores principales o llamado también factores retenidos (Pizarro y Martínez, 2020).

El AP es un método basado en simulaciones que compara los valores propios (eigenvalores) obtenidos de los datos reales con los eigenvalores generados aleatoriamente en matrices de datos simulados del mismo tamaño. Si un eigenvalor real es mayor que el eigenvalor aleatorio correspondiente, se sugiere retener ese factor o componente.

Codificadores (autoencoders)

En los últimos años, la psicometría ha incorporado progresivamente enfoques de aprendizaje automático y aprendizaje profundo para complementar los modelos estructurales tradicionales. En particular, los autocodificadores y autocodificadores variacionales han sido propuestos como alternativas para representar patrones latentes, reducir dimensionalidad y modelar relaciones potencialmente no lineales en datos psicológicos y educativos. A diferencia del ACP, que se basa en combinaciones lineales de las variables observadas, los autocodificadores pueden aprender representaciones comprimidas en un espacio latente mediante arquitecturas neuronales, lo cual resulta relevante cuando se exploran estructuras complejas de respuesta. Estudios recientes han aplicado estos enfoques en el desarrollo de formas abreviadas de pruebas psicométricas, en modelos de análisis factorial profundo y en la estimación de modelos de respuesta al ítem con variables latentes correlacionadas, lo que justifica su inclusión como estrategia comparativa en estudios orientados a caracterizar la dimensionalidad de escalas psicológicas (Casella et al., 2024).

⁴ El nombre del método hace referencia su creador, el psicólogo John L. Horn.

Los autoencoders son redes neuronales de aprendizaje no supervisado que generan nuevos datos comprimiendo la entrada en un espacio latente y, a partir de esa representación, reconstruyen la salida; los datos así obtenidos son más fáciles de entender y modelar. Estas redes constan de dos componentes principales: el codificador, que reduce la matriz de entrada a un espacio latente, y el decodificador, que recrea la matriz original a partir de dicho espacio (Esquivel et al., 2019).

De acuerdo con Milano et al., (2024), los autocodificadores constituyen una alternativa metodológica útil para explorar representaciones latentes y posibles relaciones no lineales en datos psicológicos. En este estudio, su uso no pretende sustituir al análisis factorial, sino complementar la comparación entre métodos estructurales, al permitir contrastar la información capturada por enfoques lineales tradicionales, como el AF y el ACP, frente a un modelo más flexible basado en redes neuronales.

Los autoencoders tienen un parecido significativo con el ACP, con dos diferencias principales. En primer lugar, el autocodificador es una transformación no lineal, al contrario del ACP, lo que hace que el autocodificador sea más flexible y potente. En segundo lugar, los ejes encontrados por un ACP son ortogonales y están ordenados en términos de la cantidad de variabilidad que presentan los datos a lo largo de estos ejes. Una desventaja de esta herramienta comparado con el ACP es que presenta una menor capacidad de interpretación, sin embargo, tiene la virtud de un tratamiento de datos más allá de la linealidad, y la desventaja señalada se compensa con la capacidad del investigador de proponer un algoritmo iterativo que aumente progresivamente el tamaño del espacio latente, aprendiendo una nueva dimensión en cada paso (Ladjal et al., 2019).

Actualmente, entre sus usos se centra en reducir la dimensionalidad, ya que aprenden modelos basados en funciones no lineales, lo cual contrasta significativamente con el ACP.

Metodología

Para el presente estudio se utilizó una base secundaria⁵ sobre la Escala de Autoestima de Rosenberg constituida por 10 ítems, constituida por una

5 La base de datos original está disponible en: https://openpsychometrics.org/_rawdata/

muestra aleatoria de 1000 participantes obtenido de 47974 registros de la base de datos original. En virtud de que el objetivo del estudio fue comparar la información aportada por distintos métodos estructurales —AF, ACP, análisis paralelo y autocodificadores—, el análisis se centró en la estructura de asociación entre ítems y en los patrones multivariados de respuesta, sin realizar inferencias asociadas a características poblacionales específicas; así, los datos sociodemográficos no se consideraron indispensables, aunque su ausencia sí limita posibles interpretaciones en los resultados.

Las herramientas del procesamiento de datos fueron: R y Python. Los datos que han servido de base para las simulaciones corresponden a los resultados obtenidos de la aplicación de *la escala de autoestima de Rosenberg* (The Rosenberg Self-Esteem Scale) que evalúa la autoestima global de una persona midiendo sus sentimientos positivos y negativos hacia sí misma. En la Tabla 1 se presentan la lista de los 10 enunciados/declaraciones de la escala que describen los sentires generales acerca del propio encuestado, mediante una escala de medición tipo Likert.

Tabla 1. *Escala de autoestima de Rosenberg*

No. Ítem	Ítem
Q1	I feel that I am a person of worth, at least on an equal plane with others. Siento que soy una persona valiosa, al menos en un plano de igualdad con los demás.
Q2	I feel that I have a number of good qualities. Siento que tengo una serie de buenas cualidades.
Q3	All in all, I am inclined to feel that I am a failure. En general, tiendo a sentir que soy un fracaso.
Q4	I am able to do things as well as most other people. Soy capaz de hacer las cosas tan bien como la mayoría de las personas.
Q5	I feel I do not have much to be proud of. Siento que no tengo mucho de lo que enorgullecerme.
Q6	I take a positive attitude toward myself. Tengo una actitud positiva hacia mí mismo.
Q7	On the whole, I am satisfied with myself. En general, estoy satisfecho conmigo mismo.
Q8	I wish I could have more respect for myself. Me gustaría poder tener más respeto por mí mismo.

Q9	I certainly feel useless at times. Sin duda, a veces me siento inútil.
Q10	At times, I think I am no good at all. A veces, creo que no sirvo para nada.

Fuente: (i) Traducción libre de los autores. (ii) Clave de puntuación: 4 =Totalmente de acuerdo; 3 =De acuerdo; 2 =En desacuerdo; 1 =Totalmente en desacuerdo. (iii) Ítems invertidos:⁶ 3, 5, 8, 9 y 10.

Análisis e interpretación

Análisis Factorial

Una vez aplicado el algoritmo que se ha programado en R, los resultados de la matriz de cargas factoriales muestra cómo cada ítem (Q1-Q10) se asocia con los tres factores extraídos, Tabla 2

Tabla 2. Matriz de cargas factoriales para cada ítem (Q1-Q10) asociados a los tres factores extraídos

Ítem	ML3	ML2	ML1	h2	u2	Comunalidad
Q1	0.23	0.79	0.24	0.73	0.27	1.4
Q2	0.24	0.75	0.19	0.66	0.34	1.3
Q3	0.54	0.36	0.36	0.55	0.45	2.6
Q4	0.24	0.58	0.21	0.45	0.55	1.6
Q5	0.50	0.37	0.32	0.50	0.50	2.6
Q6	0.42	0.48	0.56	0.72	0.28	2.8
Q7	0.40	0.38	0.68	0.77	0.23	2.3
Q8	0.51	0.18	0.28	0.38	0.62	1.8
Q9	0.81	0.21	0.17	0.73	0.27	1.2
Q10	0.78	0.31	0.22	0.76	0.24	1.5

Fuente: elaboración propia.

6 Los ítems invertidos son aquéllos que por su significado o su formulación miden en sentido contrario al resto del cuestionario.

Interpretación de las cargas factoriales

Los ítems que tienen cargas altas (> 0.50) en un solo factor indican una fuerte relación con ese factor; dado que Q6 y Q7 tienen cargas similares pueden representar ítems que contienen elementos de más de un constructo. La comunalidad (h^2) representa la cantidad de varianza explicada por los factores en cada ítem; la unicidad ($u^2=1-h^2$) indica la varianza no explicada por los factores, es decir, ruido o influencia de otros constructos no modelados.

El AF sintetiza la información del instrumento en tres factores, en la Tabla 3 se explicita la proporción de varianza de cada factor y la varianza acumulada

Tabla 3. Varianza explicada para cada uno de los tres factores

Factor	SS Loadings	Proporción de Varianza	Acumulada
ML3	2.58	26%	26%
ML2	2.34	23%	49%
ML1	1.31	13%	62%

Fuente: elaboración propia.

Interpretación de la varianza explicada. Los tres factores explican el 62% de la varianza total de la escala; en ML3 explica el 26%, ML2 el 23%, y ML1 el 13%.

Interpretación de los factores extraídos. Para interpretar los factores, es útil observar los ítems que tienen mayores cargas en cada factor. El factor ML3 relacionado con Q9 (0.81) y Q10 (0.78), sugiere que puede representar “Autoaceptación” o “Autoestima positiva”. El factor ML2 está fuertemente asociado con Q1 (0.79) y Q2 (0.75), posiblemente relacionado con “Seguridad en sí mismo”. El factor ML1 está más relacionado con Q7 (0.68) y Q6 (0.56), lo que podría estar asociado a “Autoeficacia” o “Autovaloración en situaciones desafiantes”.

La proporción de varianza explicada por cada factor se obtiene dividiendo su SS Loading entre el número de ítems; en la Tabla 4 se explicita la relación entre SS Loadings y la proporción de varianza explicada.

Tabla 4. La proporción de varianza explicada por cada factor con base en el SS Loadings

Factor	SS Loadings	Proporción de Varianza Explicada
ML3	2.58	26%
ML2	2.34	23%
ML1	1.31	13%

Fuente: elaboración propia.

Análisis de Componentes Principales (ACP)

En la Tabla 5 se muestran los resultados que ofrece R con el método ACP; se puede apreciar que, no obstante, de que presenta diez componentes, los identificados como PC1 y PC2 representan el 66.86% de la varianza explicada.

Tabla 5. Resultados obtenidos con R con el método ACP

Componente	Desviación estándar	Proporción de varianza	Varianza acumulada
PC1	2.3695	56.14%	56.14%
PC2	1.0354	10.72%	66.86%
PC3	0.8072	6.52%	73.38%
PC4	0.7471	5.58%	78.96%
PC5	0.7052	4.97%	83.93%
PC6	0.6772	4.59%	88.52%
PC7	0.6005	3.61%	92.13%
PC8	0.5330	2.84%	94.97%
PC9	0.5092	2.59%	97.56%
PC10	0.4941	2.44%	100.00%


Fuente: elaboración propia.

Con objeto de identificar cuántos componentes habría de retener, se aplicó el criterio de Kaiser ($\lambda > 1$), cuya regla señala que se deben mantener los componentes con eigenvalores mayores a 1. Esto lleva a conservar sólo


los dos primeros factores, dado que el punto de inflexión (o codo) se encuentra en el componente PC2, lo que se puede apreciar en la gráfica de sedimentación, ver Figura 1.

Figura 1. Los componentes resaltados en rojo PC1 y PC2 son los únicos que cumplen con el criterio, lo que ratifica la decisión de solamente retener a dos componentes principales.

Gráfica de sedimentación



Gráfica de sedimentación (con MP)



Fuente: elaboración propia.

Análisis por el Método Paralelo (MP)

Para determinar el número de componentes a mantener en el análisis de factores principales⁷ se corrió en R un análisis paralelo, que sugiere que existen cuatro factores latentes, lo que indica que la escala de autoestima podría tener cuatro dimensiones subyacentes y sólo un componente principal que explica una varianza significativamente mayor que la obtenida por datos aleatorios. Esto indica que la información de la escala está concentrada en una única dimensión cuando se usa ACP. La autoestima está caracterizada por cuatro factores latentes, sin embargo, el resultado de una componente puede implicar la unidimensionalidad del constructo.

En el gráfico de sedimentación de la Figura 1, en el eje vertical se representan los autovalores, y en el eje horizontal se representa al número de factores. La línea azul con cruces representa los datos reales provenientes de componentes principales; la línea azul con triángulos representa los datos reales del AF; las líneas rojas con cruces representan los datos simulados provenientes de componentes principales y del AF; la línea horizontal, llamada línea base, que parte de la ordenada con valor uno (color negro) sirve para determinar cuáles factores deben ser retenidos y que corresponden a aquellos que se encuentran por encima de dicha línea base, que en este caso corresponden sólo a dos provenientes de componentes principales.

Autoencoders

La implementación se realizó en Python de los datos y los resultados de los factores latentes están dados en la Tabla 6.

⁷ También llamado factores retenidos.

Tabla 6. Resultados en Python para el método de Autoencoders

	Factor 1	Factor 2	Factor 3
0	1.743882	-0.927340	5.953139
1	0.673227	-2.439257	2.399637
2	-0.610066	-2.581138	-2.032968
3	0.877581	0.437267	0.954142
4	1.184814	-1.725340	0.757745

Fuente: elaboración propia.

Resultados

El modelo factorial con tres factores parece capturar una estructura significativa en la escala de autoestima de Rosenberg. Así, ML3 es el factor más fuerte, posiblemente relacionado con autoaceptación; ML2 podría representar seguridad en sí mismo, y ML1 la autoeficacia. La varianza total explicada es del 62%, lo que sugiere que el modelo es adecuado pero aún deja un 38% de varianza sin explicar. Algunos ítems (como Q6 y Q7) tienen cargas similares en múltiples factores, lo que sugiere que pueden representar aspectos interrelacionados de la autoestima. Los ítems que conforman cada uno de los factores se encuentran en la Tabla 7.

Tabla 7. Relación factores-ítems

Factor	Ítems
ML3(Factor 3)	Q3, Q5, Q8, Q9, Q10
ML2(Factor 2)	Q1, Q2, Q4
ML1(Factor 1)	Q6, Q7

Fuente: elaboración propia.

Para el ACP, el componente dominante es el factor central de la autoestima y es el PC1; PC2 agrega información relevante, pero en menor proporción; no obstante, es conveniente conservarlo. Es razonable reducir la dimensionalidad a dos componentes, y si se desea aumentar el porcentaje de varianza explicada se podría incluir a PC3.

El modelo de autoencodificador reduce la dimensionalidad de los datos originales de la escala de autoestima de Rosenberg a tres factores latentes. El factor 1 podría estar relacionado con un componente general de autoestima; el factor 2 podría representar autoestima negativa o dudas sobre el autoconcepto; y el factor 3 podría estar más relacionado con autoafirmación o confianza personal. Y toma en cuenta que este método permite capturar representaciones comprimidas y no lineales de los datos.

Comparación de los modelos tradicionales (AF, ACP y MP) y los Autoencoders

En la Tabla 8 se presenta un comparativo de la información que proporciona cada uno de los métodos utilizados: AF, ACP, MP y Autoencoders.

Tabla 8. *Comparativo de los cuatro métodos AF, ACP, MP y Autoencoders*

Aspecto	Análisis Factorial (AF)	Análisis de Componentes Principales (ACP)	Análisis Paralelo (MP)	Autoencoder
Estructura latente	3 Factores	1 Componente dominante	4 Factores 1 Componente	3 Factores
Varianza explicada	62%	56.1%	No	No definida
Captura relaciones no lineales	No	No	No	Sí
Basado en correlaciones lineales	Sí	Sí	Sí	No
Uso práctico	Modelo más detallado pero basado en correlaciones	Simplicidad, pero con posible pérdida de información	Determinar el número óptimo de factores en AF o ACP	Mejor representación de relaciones complejas

Fuente: elaboración propia.

Limitaciones metodológicas del estudio

Dado que la base analizada no incluyó variables sociodemográficas ni información sobre el contexto o procedimiento original de aplicación, si bien es una limitación del estudio, esta ausencia no impide el análisis comparativo de los métodos estructurales aplicados a la matriz de respuestas, pero sí restringe el alcance interpretativo de los resultados. Por ello, los resultados deben entenderse como una comparación metodológica de técnicas aplicadas a la estructura interna de las respuestas disponibles.

Reflexiones finales y conclusiones

No existe, pues, una recomendación universal respecto a cuándo aplicar AF, ACP, MP o autoencoders para caracterizar los factores latentes en la escala de autoestima de Rosenberg; sin embargo, lo que está claro es que, sea cual sea el modelo o la secuencia de modelos elegida, el investigador debe justificar su decisión adecuadamente. Si se busca interpretar los resultados en términos psicológicos claros, el AF es mejor. Si se busca capturar estructuras latentes más complejas y no lineales, el autoencoder es una opción más poderosa. El ACP es útil si se desea una reducción de dimensionalidad extrema sin perder demasiada información. Finalmente, la combinación de uno o varios modelos para hallar la dimensionalidad de factores latentes podría ser necesaria para confirmar la validez de la decisión del investigador.

Conflicto de intereses

Los autores declaran no tener algún conflicto de intereses.

Referencias

- Bech, J. (2019). *Análisis Multivariado*. Universidad Autónoma de Aguascalientes.
- Casella, M., Dolce, P., Ponticorvo, M., Milano, N., y Marocco, D. (2024). Artificial neural networks for short-form development of psychometric tests: A study on synthetic populations using autoencoders. *Educational and Psychological Measurement*, 84(1), 62–90. <https://doi.org/10.1177/00131644231164363>

- Davis, C., Kellett, S., & Beail, N. (2009). Utility of the Rosenberg Self-Esteem Scale. *American Journal on Intellectual and Developmental Disabilities*, 114(3), 172–178. <https://doi.org/10.1352/1944-7558-114.3.172>
- De la Fuente-Fernández S. (2011). Análisis Factorial. Facultad de Ciencias Socioeconómicas y Empresariales UAM.
- Esquivel, N., Peralta, B. y Nicolis, O. (2019). Crime Level Prediction using Stacked Maps with Deep Convolutional Autoencoder. CHILECON 2019, October 29-31, Valparaíso, Chile 1-7. <https://doi.org/10.1109/CHILECON47746.2019.8988082>
- Jhangiani, R., Chiang, I., Cuttler, C., & Leighton, D. (2019). Métodos de Investigación en Psicología (4 ed.). (U. P. Kwantlen, Ed.) <https://doi.org/10.17605/OSF.IO/HF7DQ>
- Jiménez-García, L., López-Cepero, J., Saavedra-García, F., y García-González, A. (2018). Evaluación de estrategias de aprendizaje mediante la escala ACRA abreviada para estudiantes universitarios. *Revista Psicodidáctica*, 23(1), 1136–1034. <https://doi.org/10.1016/j.psicod.2017.03.001>
- Jolliffe, I.T. y Cadima, J. (2016). Principal component analysis: a review and recent developments. *Phil. Trans. R. Soc. A* 374: 20150202. <https://doi.org/10.1098/rsta.2015.0202>
- Ladjal, S., Alasdair Newson, A., y Pham, C.H. (2019) A PCA-like Autoencoder. <https://doi.org/10.48550/arXiv.1904.01277>
- Martín-Albó, J., Nuñez-Alonso, J., Navarro, J., y Grijalvo, F. (2007). The Rosenberg Self-Esteem Scale: Translation and Validation in University Students. *The Spanish Journal of Psychology*, 10(2), 458–467. <https://doi.org/10.1017/s1138741600006727>
- Milano, N., Casella, M., Esposito, R. y Marocco, D. (2024). Exploring the potential of variational autoencoders for modeling nonlinear relationships in psychological data. *Behavioral Sciences*, 14(7), 527. <https://doi.org/10.3390/bs14070527>
- Pérez, C. (2004). *Técnicas de Análisis Multivariante de Datos*. Pearson Educación.
- Pizarro, K., y Martínez, O. (2020). Análisis factorial exploratorio mediante el uso de las medidas de adecuación muestral kmo y esfericidad de bartlett para determinar factores principales. *Journal of Science and Research*, 5(CININGEC), 903–924. <https://revistas.utb.edu.ec/index.php/sr/article/view/1046>
- Schreiber, J. B. (2021). Issues and recommendations for exploratory factor analysis and principal component analysis. *Research in Social and Administrative Pharmacy*, 17(5), 1004–1011. <https://doi.org/10.1016/j.sapharm.2020.07.027>
- Tafarodi, R. y Swann, W. (1995). Self-Liking and Self-Competence as Dimensions of Global Self-Esteem: Initial Validation of a Measure. *Journal of Personality Assessment*, 65(2), 322–342. https://doi.org/10.1207/s15327752jpa6502_8