

El análisis factorial exploratorio de los ítems: análisis guiado según los datos empíricos y el software

Susana Lloret, Adoración Ferreres*, Ana Hernández e Inés Tomás

Behavioral Sciences Methodology Department and IDOCAL Research Institute. Universitat de València (España)

Resumen: El objetivo del presente trabajo es ilustrar cómo la aplicación adecuada o inadecuada del análisis factorial exploratorio (AFE) puede llevar a conclusiones muy diferentes. Para ello se evalúa el grado en que cuatro paquetes estadísticos diferentes que permiten realizar AFE de ítems, en concreto SPSS, FACTOR, PRELIS y MPlus, permiten o limitan la aplicación de los estándares actualmente recomendados en materia de análisis factorial. Asimismo se analizan y comparan los resultados que ofrecen dichos programas cuando se factorizan datos empíricos de escalas que ajustan, según el caso, de manera inadecuada, ambigua u óptima a los supuestos del modelo AFE lineal clásico, a través de las distintas posibilidades que ofrecen los distintos programas. Los resultados de la comparación ilustran las consecuencias de elegir entre un programa u otro, y también las consecuencias de elegir entre unas opciones u otras dentro de un mismo programa, en función de la naturaleza de los datos. Finalmente se ofrecen una serie de recomendaciones prácticas dirigidas a los investigadores aplicados con cierta orientación metodológica.

Palabras clave: Análisis Factorial Exploratorio; SPSS; FACTOR; PRELIS; MPlus.

Title: The exploratory factor analysis of items: guided analysis based on empirical data and software.

Abstract: The aim of the present study is to illustrate how the appropriate or inappropriate application of exploratory factor analysis (EFA) can lead to quite different conclusions. To reach this goal, we evaluated the degree to which four different programs used to perform an EFA, specifically SPSS, FACTOR, PRELIS and MPlus, allow or limit the application of the currently recommended standards. In addition, we analyze and compare the results offered by the four programs when factor analyzing empirical data from scales that fit the assumptions of the classic linear EFA modeling adequately, ambiguously, or optimally, depending on the case, through the possibilities the different programs offer. The results of the comparison show the consequences of choosing one program or another; and the consequences of selecting some options or others within the same program, depending on the nature of the data. Finally, the study offers practical recommendations for applied researchers with a methodological orientation.

Key words: Exploratory Factor Analysis; SPSS; FACTOR; PRELIS; MPlus.

Introducción

Este artículo es la continuación de “El análisis factorial exploratorio de los ítems: una guía práctica revisada y actualizada” (Lloret, Ferreres, Hernández y Tomás, 2014), publicado en esta misma revista. En aquel artículo y el que le sigue “El análisis factorial exploratorio de los ítems: algunas consideraciones adicionales” (Ferrando y Lorenzo-Seva, 2014) se presentaron los estándares actualmente recomendados para el investigador aplicado en materia de Análisis Factorial Exploratorio (AFE). En esta segunda parte revisaremos y resumiremos el grado en que cuatro paquetes estadísticos diferentes, SPSS 22.0, FACTOR versión 10.3.01 (Lorenzo-Seva y Ferrando, 2006, 2013), PRELIS¹ versión 9.10 (Jöreskog y Sörbom, 2007) y Mplus versión 6.12 (Muthén y Muthén, 2007, 1998-2012), permiten o limitan la aplicación de estos estándares; y en segundo lugar, analizaremos los outputs que ofrecen dichos programas cuando se factorizan datos empíricos de escalas que se ajustan, según el caso, de manera inadecuada, ambigua u óptima, a los supuestos del modelo del AFE lineal clásico. Estos tres casos prácticos con datos reales nos permitirán comparar las consecuencias de elegir entre un software u otro, y también las consecuencias de elegir entre unas opciones u otras dentro de un mismo software, cuando los datos son más o menos “problemáticos”. Nuestro objetivo es claro: ilustrar cómo la aplicación adecuada o inadecuada del AFE puede llevar a conclusiones muy diferentes.

SPSS, FACTOR, PRELIS, y Mplus varían respecto al grado en que permiten la aplicación de los estándares actuales. Siguiendo la breve guía que elaboramos en la primera parte, sería deseable que estos programas presentaran todas las opciones recogidas en la Tabla 1, o al menos la mayoría. Pero no todos lo hacen.

La información recogida en la Tabla 1, muestra que el programa más completo es FACTOR, el único específicamente diseñado para el AFE, y además de libre distribución. Sólo le falta añadir algún método de extracción de factores como mínimos cuadrados ponderados, y sus autores ya están trabajando en ello (Ferrando y Lorenzo-Seva, 2014). El punto fuerte de Mplus son los métodos de extracción de factores. Pero omite un aspecto básico como es la evaluación de la adecuación de la matriz para ser factorizada, y limita al investigador en los criterios de selección de factores que ofrece. PRELIS aún limita más al investigador, porque no permite determinar el número de factores que quiere extraer: lo hace automáticamente aplicando el criterio de Kaiser (Kaiser, 1958). Finalmente, la limitación más determinante que SPSS impone es que sólo permite analizar los ítems desde el enfoque lineal. Para más información, consúltese el anexo que ofrece un resumen de las posibilidades y limitaciones de los programas SPSS, FACTOR, PRELIS y Mplus.

*** Correspondence address [Dirección para correspondencia]:**

Adoración Ferreres Traver. Department of Methodology of Behavioral Sciences. Faculty of Psychology. University of València. Av. Blasco Ibáñez, 21. 46101, Valencia (Spain). E-mail: Adoracion.Ferreres@uv.es

¹ PRELIS es el preprocesador de LISREL.

Tabla 1. Opciones que permite cada uno de los programas analizados

	SPSS	FACTOR	PRELIS	MPLUS
TIPO DE DATOS				
Análisis de la distribución de cada ítem	NO	SI	SI	NO
Enfoque lineal o no lineal ^(a)	NO	SI	SI	SI
Medidas de adecuación de la matriz	SI	SI	NO	NO
EXTRACCIÓN DE FACTORES				
Máxima Verosimilitud (ML)	SI	SI	SI	SI
Máxima Verosimilitud Robusta	NO	NO	NO	SI ^(b)
Mínimos Cuadrados Ordinarios (ULS)	SI	SI	SI ^(c)	SI
Mínimos Cuadrados Ponderados (WLS)	NO	NO	NO	SI
WLS Robustos	NO	NO	NO	SI ^(d)
SELECCIÓN DEL NÚMERO DE FACTORES				
Basados en la varianza explicada:				
Kaiser	SI	SI ^(e)	SI	SI ^(e)
Análisis Paralelo (PA)	NO	SI	NO	NO
Basados en minimización de residuales:				
MAP	NO	SI	NO	NO
RMSR	NO	SI	NO	SI
GFI	NO	SI	NO	NO
Basados en la bondad de ajuste:				
Chi-cuadrado	SI	SI	NO*	SI
CFI / NNFI	NO	SI	NO*	SI
RMSEA	NO	SI	NO*	SI
MÉTODO DE ROTACIÓN				
Ortogonal	SI	SI	SI	SI
Oblicuo	SI	SI	SI ^(f)	SI
Especificación de matriz diana	NO	SI	NO	SI

ML = Maximum likelihood; ULS = Unweighted Least Squares; WLS = Weighted Least Squares.

^(a) El enfoque lineal analiza la matriz de correlaciones de Pearson; el enfoque no lineal analiza la matriz de correlaciones policóricas o tetracóricas, según el caso.

^(b) En Mplus, los métodos robustos de ML son MLM y MLMV.

^(c) En PRELIS, el método análogo a ULS es MINRES (Jöreskog, 2003).

^(d) En Mplus, los métodos robustos de WLS son WLSM y WLSMV.

^(e) El programa ofrece información acerca de este criterio aunque no es una opción a elegir, se ofrece cuando se usa ML como método de estimación.

^(f) PRELIS sólo ofrece la matriz de configuración en la rotación oblicua.

Teniendo en cuenta los estándares actualmente recomendados para la realización del AFE (Ferrando y Lorenzo-Seva, 2014; Lloret et al., 2014) y las opciones de los distintos programas (cuyas principales características y puntos fuertes y débiles se describen en el Anexo) se puede ofrecer una o varias hojas de ruta recomendables para cada programa. Esperamos que éstas resulten útiles para el investigador aplicado. La hoja de ruta recomendada para el programa SPSS es la siguiente: 1) se analizan ítems con dificultad y discriminación media, y un suficiente número de categorías de respuesta (mínimo 5), que presenten distribuciones aproximadamente normales; 2) mediante el método de estimación de máxima verosimilitud (ML, *Maximum Likelihood*) o mínimos cuadrados no ponderados (ULS, *Unweighted Least Squares*), te-

niendo en cuenta que ML proporciona indicadores “fiables” de la bondad de ajuste del modelo, aunque a veces presenta problemas de no-convergencia en la estimación o pueden aparecer casos *Heywood*², mientras que ULS es más robusto en las estimaciones (especialmente en soluciones complejas), pero menos robusto en la evaluación de la bondad de ajuste; 3) combinando los diferentes criterios de selección de factores (Kaiser, gráfico de sedimentación o *scree-test*, varianza explicada y la teoría de partida); y 4) optando por una rotación oblicua como PROMAX u OBLIMIN. Mucho cuidado, SPSS puede ser usado de la peor manera posible con la famosa combinación “*Little Jiffy*”, que es la que aparece seleccionada por defecto en las opciones del programa: componentes principales sobre cualquier tipo de ítems + criterio de Kaiser + rotación Varimax. Lo malo es que este tipo de análisis es todavía muy frecuente.

Para FACTOR recomendamos las siguientes dos hojas de ruta según las características de la muestra y los datos. La primera sería la que: 1) analiza el modelo no lineal en muestras grandes e ítems dicotómicos o politómicos ordinales con pocas alternativas de respuesta y que no cumplen la condición de dificultad y discriminación media; 2) estimando la matriz de correlaciones tetracóricas o policóricas; 3) utilizando el método de estimación ULS; 4) combinando los diferentes criterios de selección de factores: análisis paralelo (PA, *Parallel Analysis*) o el test MAP (*Minimum Average Partial*), bondad de ajuste cuando se usen correlaciones policóricas, minimización de los residuales, y, finalmente, la teoría de partida; y 5) optando por la rotación PROMIN, flexible pero sencilla. Otra combinación posible sería la que: 1) analiza el modelo lineal en muestras pequeñas o medianas e ítems de dificultad y discriminación media (con distribuciones aproximadamente normales) y un suficiente número de categorías de respuesta (mínimo 5); 2) estimando la matriz de correlaciones de Pearson; 3) utilizando el método de estimación ML preferentemente, o ULS si aparecen problemas de convergencia o casos *Heywood*; 4) combinando los diferentes criterios de selección de factores (PA o MAP, minimización de los residuales, índices de bondad de ajuste, y la teoría de partida); y 5) optando por la rotación PROMIN, flexible pero sencilla. La opción menos recomendable es la que analiza el modelo no lineal en muestras pequeñas o en tests con un elevado número de ítems utilizando el método ULS, porque este método no ponderado, en estas circunstancias, ofrece soluciones con problemas en la evaluación del ajuste.

Para PRELIS aconsejamos seguir una de estas dos hojas de ruta, según las características de la muestra y los datos. 1) Para muestras pequeñas o medianas, cuando el modelo lineal es una aproximación adecuada a los datos por tratarse de ítems con un número suficiente de categorías (mínimo 5) que ajustan razonablemente a una distribución normal; 2) se factoriza la matriz de correlaciones de Pearson; 3) mediante

² Valores fuera de rango (e.g., saturaciones factoriales mayores a uno, varianzas de error negativas, etc.)

el método de estimación de ML o MINRES (*MINimum RE-Siduals*), que es equivalente a ULS; 4) usando el criterio de Kaiser, y evaluando el ajuste de los sucesivos modelos que pueden ser comparados cuando se emplea ML³; y 5) se interpreta la solución oblicua comparándola con la ortogonal (ya que ambas son proporcionadas por defecto por el programa). O bien: 1) para muestras grandes, cuando el modelo no lineal resulta más adecuado por tratarse de ítems dicotómicos o politómicos ordinales con pocas alternativas de respuesta que no cumplen la condición de dificultad y discriminación media; 2) estimando la matriz de correlaciones tetracóricas o policóricas; 3) utilizando el método de estimación MINRES (equivalente a ULS); 4) empleando el criterio de Kaiser, ya que es el único ofrecido; y 5) interpretando la solución oblicua y comparándola con la ortogonal.

Y en MPlus las dos hojas de ruta más adecuadas, según las características de la muestra y los datos, serían las siguientes: una que 1) analiza el modelo no lineal en muestras grandes e ítems dicotómicos o politómicos ordinales con pocas alternativas de respuesta y que no cumplen la condición de dificultad y discriminación media; 2) estimando la matriz de correlaciones tetracóricas o policóricas; 3) utilizando un método de estimación robusto de WLS (*Weighted Least Squares*): WLSMV (ver detalles sobre las características de los distintos métodos de estimación en el Anexo); 4) combinando los diferentes criterios de selección de factores (minimización de los residuales, índices de ajuste incrementales, y la teoría de partida); y 5) optando por una rotación oblicua como GEOMIN. Y la segunda ruta sería la que: 1) analiza el modelo lineal en muestras pequeñas o medianas e ítems de dificultad y discriminación media y un suficiente número de categorías de respuesta (mínimo 5); 2) estimando la matriz de correlaciones de Pearson; 3) utilizando el método de estimación ML, o MLMV si los datos no siguen una distribución aproximadamente normal; 4) combinando los diferentes criterios de selección de factores (minimización de los residuales, índices de ajuste incrementales y la teoría de partida); y 5) optando por una rotación oblicua como GEOMIN.

Como es predecible, no podemos generar un algoritmo que guíe las decisiones del investigador a través de las diferentes opciones mencionadas, pero sí podemos resumir unas pautas para proceder. La decisión arranca con el enfoque del análisis: lineal o no lineal. Esta decisión es controvertida porque confronta los dos aspectos que caracterizan a un buen modelo: simplicidad y realismo. Las dos cualidades no aparecen juntas: el modelo no lineal es realista, y el modelo lineal es simple. Conviene señalar que con frecuencia la aproximación más simple es también más útil, porque ofrece mejor ajuste (Ferrando y Lorenzo-Seva, 2014). Pero faltan estudios de simulación que permitan dar recomendaciones a este respecto, en especial en relación a los métodos de esti-

mación de factores (Muthén y Asparouhov, 2010). De momento, se puede decir que la situación óptima para aplicar el enfoque lineal es la que analiza un conjunto de ítems ordinales que se acercan al supuesto de continuidad, porque tienen una distribución normal multivariada o distribuciones normales univariadas y cinco o más categorías de respuesta (Flora, LaBrish y Chalmers, 2012). Por otro lado, una buena aproximación para el enfoque lineal es cuando se analiza un conjunto de ítems relativamente grande en una muestra comparativamente pequeña, siempre que los ítems tengan distribuciones univariadas aproximadamente normales o dificultad media, distribuciones simétricas y discriminaciones medias, y cinco o más alternativas de respuesta (Ferrando y Anguiano-Carrasco, 2010; Muthén y Kaplan, 1985). Cuando no se den estas condiciones, el enfoque no lineal será más realista (Ferrando y Lorenzo-Seva, 2013, 2014). Recordamos que es especialmente importante considerar la relación entre tamaño de la muestra, número de ítems y número de alternativas de respuesta por ítem, porque si hay muchos ítems y/o tienen 4 ó menos alternativas de respuesta, por grande que sea la muestra, las estimaciones de las correlaciones policóricas/tetracóricas serán inestables. En la Tabla 2 se resumen estas recomendaciones.

En este trabajo mostramos la aplicación de las hojas de ruta recomendadas para los cuatro paquetes estadísticos mencionados. Concretamente, analizamos la estructura factorial de tres conjuntos de escalas: las escalas de Fuerza y Flexibilidad del PSDQ (*Physical Self Description Questionnaire*) (Marsh, Richards, Johnson, Roche y Tremayne, 1994); las escalas de Autoestima y Autoconcepto del PSDQ (Marsh et al., 1994), y el test D-48 (Anstey, 1959. Adaptado por el Dpto. de I+D+i de TEA Ediciones, 1996). Se han analizado respuestas reales, con la particularidad de que esas respuestas se ajustan de manera óptima, ambigua e inadecuada, según la escala, a los supuestos del modelo del AFE lineal o clásico (Fabrigar, Wegener, MacCallum y Strahan, 1999).

Método

Muestra

Hemos utilizado dos muestras incidentales y analizado tres conjuntos de datos. El primer conjunto de datos que hemos seleccionado corresponde a las respuestas de una muestra de 914 sujetos a las escalas de Fuerza y Flexibilidad del PSDQ. Siguiendo los criterios presentados en la Tabla 2, este conjunto de datos representaría la situación óptima, ya que se ajustan de manera aceptable a los supuestos del análisis factorial clásico o lineal porque: 1) los ítems presentan distribuciones aproximadamente normales -con coeficientes de asimetría y curtosis menores a 1 en valor absoluto-; 2) se responden con 6 alternativas de respuesta; 3) el tamaño de la muestra es grande ($N=914$), y además se dan las circunstancias favorables de que hay 6 ítems para medir cada factor, y sólo dos factores. Además, estos dos factores presentan una baja correlación entre sí.

³ Como se indica más adelante, a pesar de que, en principio, aparece la opción de fijar un determinado número de factores a extraer, el programa siempre ofrece la solución sugerida por el criterio de Kaiser —ver información detallada en el anexo.

Tabla 2. Enfoque del análisis factorial (AF): Condiciones para un modelo Lineal vs. No lineal

	Modelo AF LINEAL “SIMPLE”	Modelo AF NO LINEAL “REALISTA”
TIPO DE DATOS		
Distribución de los ítems	Normalidad univariada o dificultad media y distribución simétrica	Libre
Correlaciones inter-ítem	≤ .50	Libre
Nº categorías ^(a)	≥ 5	≤ 4
Tamaño de la muestra ^(a)	Pequeño	Mediano/grande
Nº ítems ^(a)	Variable	Pequeño
Tipo de matriz	Pearson	Policórica/tetracórica
KMO	> .70	>.70
EXTRACCIÓN DE FACTORES	ML, (MLM y MLMV) ^(b) ULS (MINRES) ^(c)	ULS (MINRES) ^(c) (WLS, WLSMV) ^(b)
PROGRAMA	SPSS, FACTOR, PRELIS, MPlus	FACTOR, PRELIS, MPlus

Notas: ^(a) Estas opciones están conectadas entre sí, por lo que debe decidirse considerándolas conjuntamente.

^(b) Métodos disponibles sólo en MPlus.

^(c) MINRES es el método análogo a ULS en PRELIS.

El segundo conjunto de datos seleccionado corresponde a las respuestas de una muestra de 976 sujetos a las escalas de Autoestima y Autoconcepto Físico del PSDQ. Este conjunto de datos ofrece un ajuste ambiguo porque sólo se adecúa parcialmente a los supuestos del análisis factorial clásico o lineal ya que: 1) no se cumple la condición de posición/dificultad media (las medias de los ítems oscilan entre 4.04 y 5.11 en una escala de respuesta de 1 a 6, y los coeficientes de asimetría de 6 de los 14 ítems son mayores a 1 en valor absoluto); 2) pero las correlaciones inter-ítem oscilan entre .25 y .73, siendo el 74 % menores a .50 ($M = .42$, $DT = .13$), lo que indica que sí se cumple la condición de discriminación moderada; 3) los ítems se responden con 6 alternativas de respuesta; y 4) el tamaño de la muestra es grande ($N = 976$). Además, se dan las circunstancias favorables de que hay 6 ítems para medir un factor y 8 para medir el otro, y sólo 2 factores.

El tercer conjunto de datos corresponde a las respuestas de una muestra de 499 sujetos al Test D-48. Este test se utiliza para medir el factor “G” de inteligencia a través de las respuestas acierto/fallo que los sujetos dan a un conjunto de 44 ítems de tipo dominó con diferentes niveles de dificultad. Este conjunto de datos no se ajusta en absoluto a los supuestos del análisis factorial clásico o lineal porque: 1) no se cumple la condición posición/dificultad media (las distribuciones de los ítems son marcadamente asimétricas, unos muy fáciles y otros muy difíciles); 2) son ítems dicotómicos; 3) el tamaño de la muestra es grande ($N = 499$), 4) pero el test es largo, contiene 44 ítems; y 5) miden un factor. Además había un problema de colinealidad entre dos ítems (probablemente debida a una duplicidad por error de un ítem: su correlación era 1). Cuando detectamos esta anomalía decidimos dejarla para comprobar cómo respondía ante ella cada programa.

La recomendación del análisis factorial clásico o lineal en el primer conjunto de datos es clara, representando la condición óptima para el análisis lineal. En el segundo conjunto de datos la recomendación sobre el tipo de análisis ya no es

tan clara, aunque el enfoque lineal, más simple y robusto, es la primera opción de análisis. Aquí tenemos la condición ambigua. En el tercer conjunto, en cambio, la recomendación es el enfoque no lineal, representando la condición inadecuada para un modelo lineal.

Procedimiento

Hemos analizado cada conjunto de datos bajo varias condiciones:

- 1) Sólo con SPSS, el criterio “*Little Jiffy*”: análisis de componentes principales (CP) + criterio de Kaiser + rotación VARIMAX (VAX). Hemos incluido esta combinación porque a pesar de no ser un análisis factorial, y por lo tanto no ser una opción recomendada, es todavía la combinación más popular y más frecuentemente utilizada, quizás por ser la que aparece por defecto en SPSS (ver Izquierdo, Olea y Abad, 2014).
- 2) Con los 4 programas (SPSS, FACTOR, PRELIS y MPlus) hemos aplicado el enfoque más adecuado considerando las opciones que ofrece cada programa y los criterios presentados en las Tablas 1 y 2. En caso de haber más de un enfoque adecuado, o más de una opción adecuada dentro de un mismo enfoque, hemos empezado por aplicar la combinación más aconsejable y la hemos modificado, según los resultados encontrados.

De modo reiterativo y en cada caso hemos valorado cada solución de acuerdo a dos criterios: la plausibilidad estadística y la verosimilitud sustantiva. Consideramos una solución *estadísticamente plausible* cuando no aparecen problemas de convergencia, matrices no positivamente definidas, o casos Heywood. Estos son indicadores de que la solución alcanzada, a pesar de ser estadísticamente posible, no es plausible, sino forzada. Por otro lado, consideramos que una solución es *verosímil* cuando ofrece resultados interpretables, consistentes con el contenido de los ítems, y con el significado de los factores según la teoría.

Resultados

Escalas de Fuerza y Flexibilidad. Condición óptima para el enfoque lineal

La Tabla 3 muestra el conjunto de análisis factoriales exploratorios llevados a cabo con los cuatro programas evaluados, siguiendo el enfoque lineal, y utilizando la matriz de correlaciones de Pearson. Todos llevan a un resultado plausible y verosímil que identifica los dos factores esperados, menos el análisis con MPlus (en la versión 6.12, empleada en el presente estudio).

Cuando aplicamos “*Little Jiffy*” con SPSS obtenemos resultados similares a los obtenidos también mediante SPSS con la combinación ML + Kaiser + Oblimin, y a los obtenidos mediante FACTOR con la combinación ML + 2F + Promin: 2 factores⁴ que resultan bien definidos. Todos los ítems presentan saturaciones por encima de .50 en su factor y por debajo de .30 en el otro. En ambos programas, SPSS y

FACTOR, los criterios de selección del número de factores de cada uno llevan al mismo número de factores que habíamos fijado de antemano: dos. Por lo que respecta a PRELIS (v. 9.10), a pesar de tener la opción de fijar el número de factores en sus cuadros de diálogo, no se lo permite realmente al investigador. Entre los ejemplos puestos a prueba (los del presente trabajo y otros adicionales), si se marca la opción de retener un número menor de factores de los que se determinan según el criterio de Kaiser, el output sigue imprimiendo la solución para el número de factores sugerido por Kaiser. Si se especifica un número mayor, el programa no llega a imprimir los resultados al menos entre todos los ejemplos puestos a prueba (sólo muestra los análisis distribucionales de ítems). Sólo cuando el número de factores coincide con lo sugerido por el criterio de Kaiser, se imprime la solución. En definitiva, PRELIS aplica automáticamente la regla de Kaiser y en este caso retiene 2 factores que resultan bien definidos y consistentes con lo esperado y con los resultados de SPSS y FACTOR.

Tabla 3. Escalas de Fuerza y Flexibilidad. Condición óptima para el modelo lineal

	KMO	SELECCIÓN DE FACTORES	Nº FACTORES, Y COMPOSICION	PLAUSIBILIDAD ESTADISTICA	VEROSIMILITUD TEORICA
SPSS					
(CP+KAISER+VAX) <i>Little Jiffy</i>	.88	KAISER	2 MAYORES ($r = .22$) 39.7 % y 23.4 %	SI	SI
CONDICION ADECUADA (ML+KAISER+OBLN)	.88	KAISER, SCREE TEST, TEORIA	2 MAYORES ($r = .22$) 39.7 % y 23.4 %	SI	SI
FACTOR					
(ML+2F+PROMIN)	.88	PA (Optativo), NNFI, CFI, GFI, RMSR, TEORIA	2 MAYORES ($r = .29$) 46 % y 26 %	SI	SI
PRELIS					
(ML+KAISER+PROMAX)	-----	KAISER ^(a)	2 MAYORES	SI	SI
MPLUS					
(ML+IBAI+GEOMIN)	-----	TLI, CFI, RMSEA, SRMR	4 (INADECUADA): 2 MAYORES 2 MENORES	SI	NO

Notas: CP = componentes principales; VAX = rotación varimax; ML = máximo likelihood; OBLN = rotación oblmin; 2F = 2 factores; IBAI = índices de bondad de ajuste incrementales; PA = análisis paralelo.

^(a)PRELIS también ofrece información acerca del ajuste de los diferentes modelos que estima (desde 0 factores hasta el número que sugiera el criterio de Kaiser).

En cambio, con el programa Mplus se seleccionan 4 factores. La comparación de la secuencia de modelos que estima (modelo con 0 factores, con 1 factor, con 2 factores, hasta el modelo con 9 factores, el máximo permitido) pone de manifiesto que el ajuste va mejorando conforme aumenta el número de factores. Sin embargo, a partir de 5 factores la solución ya no converge. El modelo de 4 factores es el que

presenta mejor ajuste (CFI = .998, NNFI = .993, RMSEA = .025, SRMR = .011), ciñéndonos a la comparativa de índices incrementales. Sin embargo, analizando tanto la matriz de estructura como la matriz de configuración se observa la presencia de 2 factores mayores y 2 menores. Los 6 ítems del factor de fuerza se agrupan en el primer factor, mientras que 5 de los 6 ítems de flexibilidad se agrupan en el segundo factor. El tercer factor recoge un solo ítem de flexibilidad; y en el factor 4 ningún ítem satura por encima de .40. La solución factorial del modelo de 4 factores es plausible estadísticamente pero poco verosímil sustantivamente. Por otra parte, el modelo de 2 factores ya presenta unos índices de bon-

⁴ Sin embargo, un análisis previo de esta misma combinación realizado con la versión previa, FACTOR 9.20, ofreció una solución que no alcanzó la convergencia. Este es un ejemplo de cómo la falta de convergencia es uno de los problemas que afecta al método de estimación ML, tal como se ha indicado anteriormente.

dad de ajuste satisfactorios (CFI = .960, NNFI⁵ = .939, RMSEA = .077, SRMR = .025), cosa que no se puede decir del modelo de 1 factor (CFI = .578, NNFI = .484, RMSEA = .224, SRMR = .185). Y analizando tanto la matriz de estructura como la matriz de configuración del modelo de 2 factores, se observa una distribución acorde a la esperada y con factores bien definidos.

Escalas de Autoestima y Autoconcepto. Condición ambigua para el enfoque lineal

La Tabla 4 muestra el conjunto de análisis factoriales que realizamos sobre este conjunto de datos. Hemos analizado el enfoque lineal y el no lineal en los programas que lo permiten, que son todos menos SPSS.

Tabla 4. Escalas de Autoestima y Autoconcepto. Condición ambigua para el modelo lineal.

	KMO	SELECCIÓN DE FACTORES	Nº FACTORES, Y COMPOSICION	PLAUSIBILIDAD ESTADÍSTICA	VEROSIMILITUD TEÓRICA
SPSS					
(CP+KAISER+VAX) <i>Little Jiffy</i>	.93	KAISER	2 MAYORES 47 % y 11.2 % 1 MENOR, CON 2 ITEMS, 8 %	SI	SI
(ML+KAISER+OBLN) ^(a)	.93	KAISER, SCREE TEST,	1 HEYWOOD	NO	SI
(ULS+KAISER+OBLN) ^(a)	.93	TEORIA KAISER, SCREE TEST, TEORIA	2 MAYORES 47 % y 11.2 % 1 MENOR (.47 < r < .61)	SI	SI (SIN 2 ITEMS)
FACTOR					
(ML+2F+PROMIN) ^(a)	.93	PA/MAP NNFI, CFI, GFI, RMSR, TEORIA	2 MAYORES (r = .71) 47.3 % y 11.8 % 1 ITEM MIXTO	SI	SI
(ULS+2F+PROMIN) ^(b)	.93	PA/MAP GFI, RMSR, TEORIA	2 MAYORES (r = .73) 59.3 % y 12.1 % 1 ITEM MIXTO	SI	SI
PRELIS					
(ML+KAISER+PROMAX) ^(a)	-----	KAISER	1 HEYWOOD	NO	SI (SIN 2 ITEMS)
(MINRES+KAISER+PROMAX) ^(b)	-----	KAISER	2 MAYORES 1 MENOR 1 ITEM MIXTO	SI	SI (SIN 2 ITEMS)
MPLUS					
(ML+IBAI+GEOMIN) ^(a)	-----	TLI, CFI, RMSEA, SRMR	HEYWOOD	NO	NO
(WLSMV+IBAI+GEOMIN) ^(b)	-----		2 MAYORES (r = .91) 1 MENOR 1 ITEM MIXTO	SI	SI (SIN 2 ITEMS)

Notas: CP = componentes principales; VAX = rotación varimax; ML = máximo likelihood; OBLN = rotación oblimin; ULS = unweighted least squares (equivalente a MINRES); 2F = 2 factores; IBAI = índices de bondad de ajuste incrementales; WLSMV = weighted least squares robusto; PA = análisis paralelo; MAP = test minimum average partial.

^(a)Enfoque lineal.

^(b)Enfoque no lineal.

Cuando aplicamos “*Little Jiffy*” obtenemos resultados similares a los obtenidos para SPSS con la combinación ULS + Kaiser + Oblimin: 2 factores mayores, un factor menor y un ítem mixto. Concretamente, los 6 ítems de autoconcepto físico global se agrupan en el primer factor, junto con un

ítem de la escala de autoestima (ES6) que es mixto. La saturación de este ítem es .55 y .44 en cada factor cuando se usa CP, y .50 y .40 cuando se usa ULS. Esta tendencia de CP a sobreestimar o al menos ofrecer saturaciones más altas que los métodos de AFE propiamente dichos se repite a lo largo de los diferentes análisis y está documentada en estudios anteriores (e.g., Ferrando, Anguiano-Carrasco, 2010; Izquierdo,

⁵ También conocido como TLI.

et al., 2014). Por otro lado, 6 de los 8 ítems de autoestima se agrupan en el segundo factor (incluyendo el ítem mixto). Finalmente, otros 2 ítems de autoestima (ES1 y ES5), que resultan ser ítems redundantes por tener una redacción muy similar, se agrupan con saturaciones altas (.81 y .84 en CP, y .69 y .84 con ULS) en el tercer factor.

A pesar de que los datos no se distribuyen normalmente, si utilizáramos ML con SPSS se obtendría una solución con estimaciones que presentan valores fuera del rango permisible. En concreto, aparece un caso Heywood (una saturación de 1.027), por lo que la solución no es plausible estadísticamente. Aunque explícitamente no se hace referencia a dicha saturación, el programa avisa con el siguiente *warning*: “se han encontrado una o más comunalidades mayores que 1 durante las iteraciones. La solución resultante deberá interpretarse con precaución”. Tras eliminar el ítem mixto ES6 y uno de los ítems redundantes (ES5), el modelo de 2 factores resulta adecuado, aunque el ítem ES1 (ítem 1 de la escala de autoestima) que aparecía en el factor menor presenta ahora una saturación marginal de .35.

FACTOR ofrece prácticamente los mismos resultados bajo el enfoque lineal o no lineal: los 2 factores esperados bien definidos, aunque de nuevo ES6 se presenta como ítem mixto. La combinación lineal “Pearson + ML + 2F + Promin” ofrece saturaciones ligeramente inferiores a la combinación análoga “Policóricas + ULS + 2F + Promin”. Hemos comparado el ajuste del modelo de 2 factores bajo cada enfoque en los criterios disponibles en ambos casos: GFI y RMSR. GFI es igual en ambos enfoques (.99) y RMSR es ligeramente mejor en el enfoque lineal (.046 frente a .048). Tal como apuntan Ferrando y Lorenzo-Seva (2014), incluso en condiciones en que el modelo no lineal debería ajustar mejor, el modelo lineal presenta mejor ajuste. Por otro lado, cabe comentar que en ambos enfoques (lineal y no lineal), el criterio PA (análisis paralelo) recomienda 1 factor; sin embargo, al poner a prueba el modelo de 1 factor, tanto el GFI como el RMSR muestran que el ajuste es inadecuado, por lo que la conclusión es que son necesarios 2 factores, que es lo que indica la teoría. Además, el criterio MAP sí sugiere 2 factores.

Respecto a PRELIS, en el enfoque no lineal (Policórica + ULS + Kaiser) se obtienen 3 factores. Todos los ítems de la subescala de Autoconcepto físico saturan en el mismo factor (con saturaciones entre .72 y .86 en la solución PROMAX), pero los ítems de autoestima se reparten entre los otros 2 factores (con saturaciones que oscilan entre .35 y .81, en la solución PROMAX). También se detecta que el ítem ES6 es mixto. Como sucedió con SPSS, al eliminar el ítem mixto y uno de los ítems redundantes (ES5), el modelo de 2 factores resulta adecuado, aunque el ítem ES1, como sucedía con SPSS, presenta una saturación marginal igual a .38. Al utilizar el enfoque lineal disponible (Pearson + ML + Kaiser), el programa también retiene 3 factores según la regla de Kaiser. Pero se obtiene un caso *Heywood*, que el programa

indica convenientemente, por lo que no continuamos con la interpretación.

Mplus con el enfoque no lineal usando el método de estimación robusto WLSMV, recomendado en casos de no normalidad como éste (Policórica + WLSMV), no presenta ningún problema. El ajuste va mejorando conforme aumenta el número de factores. Sin embargo, a partir de 6 factores la solución ya no converge. De los modelos estimados, siguiendo el criterio de comparación de índices incrementales, el que debería seleccionarse es el de 3 factores (CFI = .987, NNFI = .977, RMSEA = .073, SRMR = .021). El modelo de 2 factores presenta índices de bondad de ajuste adecuados (CFI = .943, NNFI = .919, RMSEA = .136, SRMR = .052). Sin embargo, la mejora de ajuste del modelo de 3 factores respecto al modelo de 2 factores, no resulta trivial (Δ CFI = .044, Δ NNFI = .058, Δ RMSEA = -.063); mientras que el modelo de 4 factores presenta una mejora irrelevante respecto al modelo de 3 factores (Δ CFI = .006, Δ NNFI = .007, Δ RMSEA = -.012). El modelo de un factor presenta índices de ajuste inaceptables (CFI = .868, NNFI = .844, RMSEA = .190, SRMR = .096). Con Mplus aplicando el método más apropiado, en este caso el enfoque lineal (Pearson + ML), éste rodó de forma satisfactoria, y aparentemente sin problemas, ya que no apreció ningún mensaje de aviso o *warning*. Únicamente los que indicaban que a partir de un número determinado de factores (6 factores), no se alcanzaba la convergencia en el algoritmo de rotación, y por lo tanto no se estimaba el modelo de 6 factores, ni ningún otro modelo con más de 6 factores (el máximo son 9). Sin embargo, aparecen dos casos *Heywood*. Lo que implica que esos resultados no son plausibles estadísticamente. Así que no continuamos adelante con la interpretación de esta solución, interpretando únicamente los resultados del enfoque no lineal.

Analizando tanto la matriz de estructura como la matriz de configuración, se observaba que se repite el resultado de SPSS y PRELIS: 2 factores mayores y un factor menor, además del ítem mixto. Y de nuevo se comprueba que al eliminar el ítem mixto (ES6) y uno de los ítems redundantes (ES5) el modelo de 2 factores es el más adecuado (CFI = .992, NNFI = .987, RMSEA = .061, SRMR = .021), siendo la saturación del ítem ES1 marginal (.375).

D-48. Escala de Factor G. Condición inadecuada para el enfoque lineal

Recordaremos que este conjunto de datos es especialmente problemático desde el punto de vista del AFE: las distribuciones marcadamente asimétricas de ítems que son muy fáciles o muy difíciles en su mayoría, dicotómicos, en una muestra que no es suficientemente grande para el gran número de ítems, y además la duplicidad de uno de los ítems hace que sea realmente complicado analizar este conjunto de ítems con éxito. La Tabla 5 muestra el conjunto de resultados que hemos obtenido.

Tabla 5. D-48. Condición inadecuada para el modelo lineal: conjunto de datos no lineal.

	KMO	SELECCIÓN DE FACTORES	Nº FACTORES, Y COMPOSICION	PLAUSIBILIDAD ESTADÍSTICA	VEROSIMILITUD TEÓRICA
SPSS (CP+KAISER+VAX) <i>Little Jiffy</i>	NO	KAISER	12	SI	NO
(ULS+KAISER+OBLIMIN) ^(a)	NO	KAISER	12 (2 HEYWOOD)	NO	NO
	NO	FIJADO A 1	(2 HEYWOOD)	NO	NO
FACTOR (ULS+1F+PROMIN) ^(b)	.00 Inadecuado	No posible	No posible	--	--
PRELIS (MINRES+KAISER+PROMAX) (b)	-----	KAISER	13 (2 HEYWOOD)	NO	NO
MPLUS (WLSMV+IBAI+GEOMIN) ^(b)	-----	TLI, CFI, RMSEA, SRMR	6	SI	NO

Notas: CP = componentes principales; VAX = rotación varimax; ULS = unweighted least squares; 1F = 1 factor; IBAI = índices de bondad de ajuste incrementales; WLSMV = weighted least squares robusto.

^(a)Enfoque lineal.

^(b)Enfoque no lineal.

Con SPSS hemos obtenido dos veces la solución “*Little Jiffy*”: solicitando o no KMO. La sorpresa ha sido constatar que, si solicitamos KMO, el programa: 1) no lo ofrece ni indica por qué, y 2) en cambio sí informa de que la matriz de correlaciones de Pearson -la única que puede analizar- no es positivamente definida. Por lo demás la solución es perfectamente plausible. Si no solicitamos KMO, el programa realiza el análisis sin indicar ninguna anomalía. La solución que ofrece es plausible estadísticamente, pero no muy verosímil: identifica 12 componentes. Señalaremos que el decimotercer componente tiene un valor propio de .983. El criterio de Kaiser excluye este factor, pero queda patente la arbitrariedad de este criterio. De los 12 componentes, 9 tienen 3 ó más ítems con saturaciones factoriales iguales o mayores a .40. La interpretación de esos factores en términos sustantivos es muy confusa. Esta solución refleja claramente el problema de los factores de dificultad antes mencionada, donde los ítems se agrupan en función de su nivel de dificultad (Ferrando, 1994; Ferrando y Anguiano-Carrasco, 2010).

Con el método de factorización ULS, aunque la matriz no es definida positiva, este método de extracción puede factorizarla. Sin embargo, SPSS indica que la matriz factorizada tiene problemas. En concreto muestra el siguiente mensaje: “Esta matriz no es definida positiva. La extracción no se puede hacer”. No se realiza la extracción, y aparecen 2 casos *Heywood*. Todo ello es una señal de que algo anda mal. La solución que ofrece, poco fiable según advierte el programa, es una vez más la de 12 factores, de los que sólo 5 están adecuadamente definidos por 3 ó más ítems. Si fijamos el número de factores a 1, que es el número de factores esperados si realmente el test mide el factor G de inteligencia general, las comunialidades son más bajas que en los otros casos, y las saturaciones en el factor identificado son también bajas: de los 44 ítems, sólo 10 presentan saturaciones

entre .40 y .50, y sólo 3 entre .51 y .55. El porcentaje de varianza explicada por este único factor es el 14.5 %.

Con FACTOR aplicamos el enfoque no lineal, considerando los datos. Hemos factorizado la matriz de correlaciones tetracóricas combinada con el método de estimación ULS, y el método de selección de factores PA. El programa ofrece automáticamente las distribuciones de frecuencias de cada uno de los ítems junto a la información acerca de los coeficientes de asimetría y curtosis. Observamos que todos los ítems están fuera del rango aconsejado. La información preliminar que proporciona este análisis es suficiente para evidenciar que con distribuciones tan asimétricas en ambas direcciones como las que aparecen en estos datos no se puede factorizar la matriz adecuadamente. A continuación aparece la matriz de correlaciones tetracóricas, que es estimada con normalidad. Sin embargo, a partir de este punto se vuelve evidente, hasta para los investigadores menos experimentados, que los datos son inadecuados para ser sometidos a un análisis factorial. Los indicadores de la adecuación de la matriz de correlaciones que va a ser factorizada (KMO y estadístico de Bartlett) ofrecen valores interpretables, junto con la etiqueta de “inaceptable”. Además, en lugar de obtener estimaciones de los autovalores y de las saturaciones factoriales, aparecen símbolos que indican claramente que los análisis no han sido realizados. El programa informa -a su modo- que estos datos no pueden ser sometidos a análisis factorial.

Cuando usamos PRELIS, el programa estima automáticamente las pruebas de normalidad bivariada de las respuestas continuas que subyacen a los ítems dicotómicos, y también avisa de que una de las correlaciones es igual a 1. Da una solución con 13 factores que no son interpretables por contenido. En todas las soluciones impresas para las distintas rotaciones, el programa avisa de la existencia de casos *Heywood*.

Finalmente, cuando usamos MPlus, el número de factores se fijó, como en ocasiones anteriores, al máximo permitido, para obtener todas las soluciones factoriales desde 1 hasta 9 factores. Al indicar la naturaleza ordinal de los datos, el programa calculó la matriz de correlaciones tetracóricas, y el análisis rodó de forma satisfactoria, mostrando el aviso de que había ítems que presentaban correlaciones iguales a 1. A pesar de ello, se ofrecen los índices de bondad de ajuste de los diferentes modelos puestos a prueba. En las soluciones factoriales no aparecen casos *Heywood*, por lo que se puede afirmar que este método de extracción de factores es realmente robusto para el análisis de ítems categóricos, incluso con distribuciones muy asimétricas y con una correlación de 1 entre dos de los ítems. El modelo de un factor, esperable teóricamente, presenta un ajuste claramente inaceptable (CFI = .696, NNFI = .681, RMSEA = .050, SRMR = .216). A medida que aumenta el número de factores, el ajuste mejora de forma progresiva. Para decidir qué modelo presenta mejor ajuste, se aplicó la comparativa de índices de ajuste incrementales. En base a estos criterios, el modelo a seleccionar es el de 6 factores (CFI = .972, NNFI = .962, RMSEA = .017, SRMR = .08), ya que la mejora del ajuste respecto al modelo de 5 factores no resulta trivial (Δ CFI = .015, Δ NNFI = .018, Δ RMSEA = .004); mientras que el modelo de 7 factores presenta una mejora irrelevante respecto al modelo de 6 factores (Δ CFI = .009, Δ NNFI = .010, Δ RMSEA = .002). La solución factorial del modelo de 6 factores es estadísticamente plausible, aunque este resultado no apoya el modelo teórico unifactorial que defiende la teoría. Si solamente consideráramos este análisis, la conclusión a la que llegaríamos es que el D-48 es multidimensional. Eso sí, la interpretación de esas dimensiones sería bastante dificultosa, porque los 6 factores identificados parecen agrupar los ítems por sus niveles de dificultad. Este método de extracción (WLSMV) permite hacer una interpretación más objetiva de los ítems que saturan en cada factor porque ofrece los errores típicos de estimación de cada saturación, y por lo tanto permite tener una idea de lo que se desvían del hipotético valor de 0. En este análisis la clave de que algo va mal no está en los resultados estadísticos obtenidos, sino en su interpretación sustantiva: desde este punto de vista, los resultados son sencillamente incongruentes con la teoría que asume la unidimensionalidad del factor G.

Discusión

El objetivo de este trabajo no es dar recetas para el AFE, sino estimular la reflexión crítica. El análisis factorial forma parte de nuestra vida cotidiana como investigadores en psicología, pero no por eso dominamos suficientemente esta técnica estadística. ¿Qué podemos aprender tras comparar tantos análisis, opciones y programas? Sobre todo, a reflexionar. Más allá de los criterios estadísticos y de los índices de bondad de ajuste, necesitamos reflexionar críticamente sobre los principios más abstractos de Plausibilidad Estadística y Verosimilitud Teórica. Aquí presentamos solamente

un ejemplo de reflexión crítica para cada conjunto de datos. El resto queda para el lector.

El conjunto de datos correspondiente al D-48 es realmente difícil de analizar tanto desde el modelo lineal como desde el no lineal. ¿Cómo lo han indicado los cuatro programas que hemos comparado? Depende del programa. En un extremo, desde el inicio FACTOR ha mostrado indicios de que los datos eran inadecuados, indica que la matriz no es adecuada para ser factorizada; por lo tanto, no la factoriza y no ofrece resultados numéricos en el output. El programa previene de un uso inapropiado del AFE. En el otro extremo, Mplus puede con todo, incluso con estos datos “difíciles”. Desde luego que el método de estimación de mínimos cuadrados ponderados robusto (WLSMV) es robusto de verdad. No aparece ninguna indicación de que algo vaya mal en los datos, aunque sí avisa de la correlación de 1 entre dos de los ítems. Es el único programa que no presenta casos *Heywood*. Y eso, ¿es bueno o malo? Desde nuestro punto de vista, esto no es bueno, ya que no alerta al investigador acerca de un conjunto de datos “difícil” para ser factorizado. Por lo tanto, puede enmascarar un problema que no es de índole estadística, sino más bien de índole sustantiva o debido a un mal diseño de la investigación. Sólo con ver el valor que alcanza KMO o el test de esfericidad de Barlett ya sería suficiente para parar y pensar más antes de interpretar la solución, que por supuesto es difícil de interpretar.

¿Qué conclusión sacamos del conjunto de datos ambiguo? Como recomiendan Ferrando y Lorenzo-Seva (2014), ante la duda hay que probar los dos enfoques, el lineal y el no lineal. Pero no sólo eso. También hay que probar con diferente número de factores: al menos el esperado según la teoría y el que recomienden los criterios (varios) considerados. Cuando se deja que empleen el criterio que usan de forma automática en SPSS, PRELIS y Mplus (Kaiser o comparación de modelos con 0 a 9 factores), los resultados apuntan a que son necesarios 3 factores para explicar las relaciones entre los ítems de estas dos escalas (Autoestima y Autoconcepto). FACTOR con PA apunta a 1 factor, y con MAP apunta a 2 factores; siendo el modelo de 2 factores el que mejor ajusta, que es el que concuerda con la teoría. Pero hay que comparar los modelos y sus índices de bondad de ajuste. No podemos confiar sin más en que el programa decida por nosotros, porque no tendrá nunca en cuenta la verosimilitud teórica, sino solamente la plausibilidad estadística.

Por último, el primer conjunto de datos que hemos analizado, el más “amable”, pone de manifiesto que MPlus, al utilizar el procedimiento de comparación de modelos, sobreestima el número de factores que recomienda seleccionar señalando como adecuada una solución de 4 factores que no tiene sentido. De nuevo la solución es estadísticamente plausible pero nada verosímil desde el punto de vista teórico: un factor con una sola saturación y otro con ninguna, son muy difíciles de interpretar. Claro que el investigador avanzado se dará cuenta de que la solución de 2 factores es satisfactoria, aunque no sea la mejor desde el punto de vista del ajuste del

modelo. Pero como decíamos antes: hay que buscar entre lo que el programa ofrece y no dejar que éste tome el control. Aquí mencionaremos que PRELIS, aunque ofrece la misma solución de 2 factores que SPSS y FACTOR, no permite al investigador tomar ninguna decisión más allá de definir el tipo de enfoque, lineal o no lineal, que se quiere usar. Lo demás lo decide el programa de forma automática, y no se puede cambiar. No hay lugar para explorar otras opciones, o un número diferente de factores (especialmente para algunos métodos de estimación).

Tras todas estas pruebas, las autoras recomendamos FACTOR: es específico, flexible, incorpora las recomendaciones actuales sobre AFE, y es de libre distribución. Pero como todo se puede mejorar, le pediríamos que fuera más “amigable”: que aportara un manual más didáctico, y que permitiera leer datos directamente desde SPSS o EXCEL. Sin embargo, en la web del programa se facilita una aplicación EXCEL que permite que los datos sean pre-procesados en EXCEL y posteriormente guardados en un fichero que FACTOR puede leer fácilmente. El programa debería también ofrecer mensajes al usuario cuando está ejecutando el

análisis, evitando que parezca que el programa se ha bloqueado, como ocurre en algunas ocasiones en la versión XP 10.3.01 o en versiones anteriores. Concretamente, la versión 10.3.01 se ofrece compilada en tres modalidades: 64-bits, 32-bits y XP. Aunque en las dos primeras modalidades este problema ha sido ya resuelto, los usuarios de la versión XP, que es más antigua, debería estar prevenido sobre este aspecto. Además, la versión de 64-bits gestiona la memoria de manera más eficiente, lo que hace posible concluir análisis que las otras modalidades finalizarían sin dar resultados. Por lo tanto, recomendamos utilizar la versión de 64 bits. También se podrían incrementar las posibilidades de análisis de datos no lineales, incorporando métodos de estimación más robustos. En lo que a esto respecta, los autores nos han informado de que pronto estará disponible una nueva versión de este programa (versión 10.4.01). Esta versión incluirá entre sus mejoras el método de estimación ULS robusto. Como podemos verificar, los autores de FACTOR continúan trabajando para mejorar aún más su programa, y desde aquí les damos las gracias.

Referencias

- Anstey, E. (1959). *Test de Dominós*. Buenos Aires: Paidós.
- Bock, R. D., Gibbons, R., & Muraki, E. (1988). Full-information item factor analysis. *Applied Psychological Measurement, 12*, 261-280. doi: 10.1177/014662168801200305
- Browne, M. W. (1972a). Orthogonal rotation to a partially specified target. *British Journal of Mathematical and Statistical Psychology, 25*, 115-120. doi: 10.1111/j.2044-8317.1972.tb00482.x
- Browne, M. W. (1972b). Oblique rotation to a partially specified target. *British Journal of Mathematical and Statistical Psychology, 25*, 207-212. doi: 10.1111/j.2044-8317.1972.tb00492.x
- Browne, M. W. (2001). An overview of analytic rotation in exploratory factor analysis. *Multivariate Behavioral Research, 36*, 111-150. doi: 10.1207/S15327906MBR3601_05
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. In K. A. Bollen & J. S. Long (Eds.): *Testing structural equation models* (pp. 136-136). Sage Publications
- Chen, F. F. (2007). Sensitivity of goodness of fit indexes to lack of measurement invariance. *Structural Equation Modeling: A Multidisciplinary Journal, 14*, 464-504. doi: 10.1080/10705510701301834
- Cheung, G. W., & Rensvold, R. B. (2002). Evaluating goodness-of-fit indexes for testing measurement invariance. *Structural Equation Modeling: A Multidisciplinary Journal, 9*, 233-255. doi: 10.1207/S15328007SEM0902_5
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods, 4*, 272-299. doi: 10.1037/1082-989X.4.3.272
- Ferrando, P. J. (1994). El problema del factor de dificultad: una revisión y algunas consideraciones prácticas [The problem of difficult factor: A revision and some practice considerations]. *Psicológica, 15*, 275-283.
- Ferrando, P. J., & Anguiano-Carrasco, C. (2010). El análisis factorial como técnica de investigación en psicología [The factor analysis as method of research in psychology]. *Papeles del Psicólogo, 31*, 18-33.
- Ferrando, P. J., & Lorenzo-Seva, U. (2013). *Unrestricted item factor analysis and some relations with item response theory*. Technical Report. Retrieved from <http://psico.fcep.urv.es/utilitats/factor/>
- Ferrando, P. J., & Lorenzo-Seva, U. (2014). El análisis factorial exploratorio de los ítems: algunas consideraciones adicionales [Exploratory item factor analysis: Some additional considerations]. *Anales de Psicología, 30*, 1170-1175.
- Flora, D. B., LaBrish, C., & Chalmers, R. P. (2012). Old and new ideas for data screening and assumption testing for exploratory and confirmatory factor analysis. *Frontiers in Quantitative Psychology and Measurement, 3*, 1-21. doi: 10.3389/fpsyg.2012.00055
- Harman, H. H. (1980). *Análisis factorial moderno [Modern factor analysis]*. Madrid: Saltés.
- Hendrickson, A. E., & White, P. O. (1964). Promax: A quick method for rotation to a simple structure. *British Journal of Mathematical and Statistical Psychology, 17*, 65-70. doi: 10.1111/j.2044-8317.1964.tb00244.x
- Horn, J. L. (1965). A rationale and test for the number of factors in factor analysis. *Psychometrika, 30*, 179-185. doi:10.1007/BF02289447
- Izquierdo, I., Olea, J., & Abad, F. J. (2014). El análisis factorial exploratorio en estudios de validación: usos y recomendaciones [Exploratory factors analysis in validation studies: Uses and recommendations]. *Psicothema, 26* (3), 395-400. doi: 10.7334/psicothema2013.349
- Jöreskog, K. G. (2002). *Structural equation modeling with ordinal variables using LISREL* (updated in 2004). Technical report. Available on http://www.ams.sunysb.edu/~zhu/tmp/Yue/SEM_brain/covariate/covari-are2/SEM%20with%20ordinal%20variables%20using%20LISREL.pdf
- Jöreskog, K. G. (2003). *Factor analysis by MINRES*. Technical report. Available on <http://www.sscicentral.com/lisrel/techdocs/minres.pdf>
- Jöreskog, K. G., & Sörbom, D. (2007). *LISREL 8.80*. [Computer Software]. Lincolnwood, IL: Scientific Software International, Inc.
- Jöreskog, K. G., Sörbom, D., Du Toit, S., & Du Doit, M. (1999). *LISREL 8: New statistical features*. Chicago: Scientific Software International.
- Kaiser, H. F. (1958). The varimax criterion for analytical rotation in factor analysis. *Psychometrika, 23*, 187-200. doi:10.1007/BF02289233
- Kaiser, H. F. (1974). An index of factorial simplicity. *Psychometrika, 39*, 31-36. doi:10.1007/BF02291575
- Kiers, H. A. L. (1994). Simplimax: Oblique rotation to an optimal target with simple structure. *Psychometrika, 59*, 567-579. doi:10.1007/BF02294392
- Lloret, S., Ferreres, A., Hernández, A., & Tomás, I. (2014). El análisis factorial exploratorio de los ítems: una guía práctica, revisada y actualizada [Exploratory item factor analysis: A practical guide revised and updated]. *Anales de Psicología, 30*, 1151-1169. doi: 10.5018/analesps.30.3.199361
- Lorenzo-Seva, U. (1999). Promin: a method for oblique factor rotation. *Multivariate Behavioral Research, 34*, 347-356. doi: 10.1207/S15327906MBR3403_3

- Lorenzo-Seva, U., & Ferrando, P. J. (2006). FACTOR: a computer program to fit the exploratory factor analysis model. *Behavioral Research Methods*, 38, 88-91. doi:10.3758/BF03192753
- Lorenzo-Seva, U., & Ferrando, P. J. (2013). FACTOR 9.2. A comprehensive program for fitting exploratory and semiconfirmatory factor analysis and IRT models. *Applied Psychological Measurement*, 37, 497-498. doi: 10.1177/0146621613487794
- Lorenzo-Seva, U., & Ferrando, P. J. (2012). TETRA-COM: A comprehensive SPSS program for estimating the tetrachoric correlation. *Behavioral Research*, 44, 1191-1196. doi:10.3758/s13428-012-0200-6
- Lorenzo-Seva, U., & Ferrando, P. J. (2015). POLYMAT-C: A comprehensive SPSS program for computing the polychoric correlation matrix. *Behavior Research Methods*, 47(3), 884-889. doi:10.3758/s13428-014-0511-x
- Lorenzo-Seva, U., & Van Ginkel, J. R. (2016). Multiple imputation of missing values in exploratory factor analysis of multidimensional scales: estimating latent trait scores. *Anales de Psicología*, 32, 596-608. doi: 10.6018/analesps.32.2.215161
- Mardia, K. V. (1970). Measures of multivariate skewness and kurtosis with applications. *Biometrika*, 57, 519-530. doi: 10.1093/biomet/57.3.519
- Marsh, H. W., Richards, G. E., Johnson, S., Roche, S., & Tremayne, P. (1994). Physical Self-Description Questionnaire: Psychometric properties and a multitrait-multimethod analysis of relations to existing instruments. *Journal of Sport and Exercise Psychology*, 16, 270-305.
- Muthén, B., & Kaplan D. (1985). A comparison of some methodologies for the factor analysis of non-normal Likert variables. *British Journal of Mathematical and Statistical Psychology*, 38, 171-189. doi: 10.1111/j.2044.8317.1985.tb00832.x
- Muthén, B., & Asparouhov, T. (2010). Bayesian SEM: A more flexible representation of substantive theory. *Psychological Methods*, 17, 313-335. doi: 10.1037/a0026802
- Muthén, L. K., & Muthén, B. O. (1998-2012). *Mplus user's guide* (7th ed.) Los Angeles, CA: Muthén & Muthén.
- Muthén, L. K., & Muthén, B. O. (2007). *Mplus user's guide* (5th ed.) Los Angeles, CA: Muthén & Muthén.
- O'Connor, B. (2000). SPSS and SAS programs for determining the number of components using parallel analysis and Velicer's MAP test. *Behavior Research Methods, Instruments, & Computers*, 32, 396-402. doi:10.3758/BF03200807
- Satorra, A., & Bentler, P. M. (2001). A scaled difference chi-square test statistic for moment structure analysis. *Psychometrika*, 66, 507-514. doi:10.1007/BF02296192
- Trendafilov, N. (1994). A simple method for procrustean rotation in factor analysis using majorization theory. *Multivariate Behavioral Research*, 29, 385-408. doi: 10.1207/s15327906mbr2904_4
- Velicer, W. F. (1976). Determining the number of components from the matrix of partial correlations. *Psychometrika*, 41, 321-327. doi:10.1007/BF02293557
- Widaman, K. F. (1985). Hierarchically nested covariance structure models for multitrait-multimethod data. *Applied Psychological Measurement*, 9, 1-26. doi: 10.1177/014662168500900101

(Artículo recibido: 21-02-2016; revisado: 05-10-2016; aceptado: 11-10-2016)

Anexo: Resumen de las posibilidades y limitaciones de SPSS, FACTOR, PRELIS y MPlus.

A continuación se presentan las posibilidades y limitaciones de cada programa más utilizados en el contexto del investigador aplicado, que complementan las hojas de ruta más adecuadas según los nuevos estándares. Algunos programas presentan opciones más avanzadas, pero por razones de espacio y dado el perfil generalista de este trabajo no entraremos en su presentación.

SPSS

1) Modelo factorial. Tipo de datos y matriz de asociación

Posibilidades que ofrece: La versión estándar de SPSS sólo permite utilizar el enfoque del modelo de análisis factorial lineal. La aproximación no lineal se puede aplicar utilizando programas adicionales de SPSS, como TETRA-COM y POLYMAT-C (Lorenzo-Seva & Ferrando, 2012, 2015). Por lo tanto, cuanto utilizamos la versión estándar, SPSS analiza la matriz de correlaciones de Pearson o la matriz de varianzas-covarianzas, sea esa la opción adecuada o no según los nuevos estándares. Este programa evalúa bajo demanda la adecuación de la matriz para su factorización mediante la medida KMO y la Prueba de Esfericidad de Barlett.

Limitaciones: SPSS no analiza directamente matrices de correlación policóricas ni tetracóricas. Aunque, tal como ya hemos indicado, existen programas para poder estimar las correlaciones policóricas o tetracóricas (Lorenzo-Seva y Ferrando, 2012, 2015), pero su análisis no aparece integrado dentro del análisis factorial. SPSS tampoco ofrece al investigador un análisis preliminar y automático de las distribuciones de los ítems.

2) Métodos de estimación de factores

Posibilidades que ofrece: SPSS permite emplear algunos de los métodos de estimación de factores recomendados: mínimos cuadrados no ponderados (*Unweighted Least Squares*, ULS), mínimos cuadrados ponderados generalizados (*Generalized Weighted Least Squares*, GWLS) y máxima verosimilitud (*Maximum Likelihood*, ML), y el más clásico ejes principales.

Limitaciones: tiene como opción por defecto componentes principales (CP). Sin embargo, sabemos que CP no es un método de análisis factorial, y por ello, es el procedimiento de estimación más desaconsejado en la actualidad para la mayoría de las aplicaciones en ciencias sociales y de la salud.

3) Método de selección de factores

Posibilidades que ofrece: Diferentes métodos basados en la varianza explicada, como el método de Kaiser –opción por defecto–, el Scree test, y la proporción de varianza explicada por cada factor. Además el investigador puede usar la opción de fijar el número de factores de acuerdo con su hipótesis. Finalmente, si se usa el método ML de estimación de factores también se obtiene el indicador de bondad de ajuste chi-cuadrado.

Limitaciones: No ofrece ninguno de los criterios más recomendables, como la bondad de ajuste del modelo factorial ajustado (que nos permitiría además comparar el ajuste de diferentes modelos rivales), ni criterios objetivos “extra” como el análisis paralelo (*Parallel Analysis*, PA) descrito por primera vez en Horn (1965) o el test MAP (*Minimum Average Partial*) (Velicer, 1976). Si bien cabe señalar que existen macros para SPSS que pueden implementarse y realizar estos análisis (O'Connor, 2000) (en la página web del autor pueden descargarse las macros para distintos programas: <https://people.ok.ubc.ca/briocconn/nfactors/nfactors.html>). SPSS tampoco ofrece un método basado en la minimización de los residuales.

4) Métodos de rotación de factores y de asignación de ítems

Posibilidades que ofrece: SPSS ofrece una variedad adecuada de métodos de rotación ortogonal y oblicua: OBLIMIN DIRECTO, PROMAX, VARIMAX, EQUAMAX Y QUARTIMAX. Todos ellos tienen como guía el principio de simplicidad factorial de Kaiser: se espera que cada ítem tenga una saturación alta en un único factor. El investigador no determina cuál es ese factor.

Limitaciones: en este tipo de rotaciones guiadas por el principio de simplicidad es muy necesario formular ítems que sean “puros” factorialmente (Ferrando y Lorenzo-Seva, 2013, 2014).

En resumen, SPSS puede ser usado de manera eficiente si se tienen en cuenta las limitaciones que presenta y se aprovechan las posibilidades que ofrece, aunque las condiciones en las que resulta adecuado son más limitadas (a no ser que se usen las macros para estimar la matriz de correlaciones tetracóricas o policóricas en el caso en que el modelo no lineal sea el más adecuado).

FACTOR

1) Modelo factorial. Tipo de datos y matriz de asociación

Posibilidades que ofrece: FACTOR permite elegir entre el modelo del análisis factorial lineal o el no lineal, porque puede analizar la matriz de correlaciones de Pearson, la matriz de varianzas-covarianzas y, en función de que se trate de datos politémicos o dico-

tómicos, la matriz de correlaciones policóricas o la matriz de correlaciones tetracóricas. Este programa ofrece de forma automática varios tests de adecuación de la matriz para su factorización, entre los que destaca la medida KMO y la Prueba de Esfericidad de Barlett. Además, ofrece al investigador un análisis preliminar y automático de las distribuciones de los ítems que va a factorizar y el test de normalidad multivariada de Mardia (1970), por lo que la elección entre el modelo del análisis factorial lineal y el no lineal es una elección informada.

Además, FACTOR 10.3.01 maneja los valores faltantes a través de un procedimiento de imputación múltiple (Lorenzo-Seva y Van Ginkel, 2016). Este es un procedimiento novedoso en el contexto del análisis factorial y no está disponible en ningún otro software comercial.

Limitaciones: FACTOR no lee directamente los datos desde Excel o SPSS, sino que requiere que el fichero de datos tenga un formato ASCII (.dat), sin etiquetas de variables, ni número de casos, ni más información que las puntuaciones en los ítems. Destacar que la web del programa ofrece un archivo excel para preprocesar los datos y guardarlos en formato ASCII. Este archivo se actualizó recientemente en la web de FACTOR para adaptarlo mejor al formato actualizado de Excel 2010/13.

2) Métodos de estimación de factores

Posibilidades que ofrece: FACTOR permite emplear los conocidos métodos de estimación ULS y ML. Además incorpora otro método menos conocido: el análisis factorial de rango mínimo. Este método tiene la particularidad de que permite interpretar la proporción de varianza común explicada por cada uno de los factores retenidos (ver Lorenzo-Seva y Ferrando, 2006, 2013).

En su última versión (10.3.01), el programa se ofrece en tres modalidades: 64 bits, 32 bits y XP. La versión más eficiente es la de 64 bits porque los resultados se pueden obtener mucho más rápidamente y se pueden gestionar conjuntos más grandes de datos. De hecho, esta versión puede finalizar análisis que las otras versiones (32 bits y XP) no pueden porque producen un error de memoria.

Limitaciones: No dispone de métodos de estimación de mínimos cuadrados ponderados (e.g., WLS), que son los recomendables en caso de que el modelo no lineal sea el adecuado, porque lleva a evaluaciones más correctas del ajuste del modelo (siempre que se cuente con muestras suficientemente grandes). La próxima versión, 10.4.01, incorporará estos métodos de estimación ponderados.

En otro orden de cosas, los análisis con las versiones de 32 bits y XP de FACTOR pueden tomar más tiempo del habitual en otros programas (principalmente cuando se realiza PA, que implica la obtención y análisis de un elevado número de muestras aleatorias mediante *bootstrap*). En ocasiones mientras se ejecuta el análisis con XP, Windows presenta el mensaje de que hay un error y parece que el análisis se ha detenido y que el programa está bloqueado, pero no, es solo cuestión de esperar. En otras ocasiones aparecen problemas y el programa efectivamente se “cuelga”, y entonces es cuando se echa en falta un mensaje de advertencia del propio programa que indique que es necesario cerrar y salir, porque el análisis no puede continuar.

3) Método de selección de factores

Posibilidades que ofrece: FACTOR requiere que el investigador indique el número de factores a retener. Pero ayuda en esta decisión porque ofrece criterios objetivos para ello: el análisis paralelo (PA), el PA optimizado (que analiza el mismo tipo de matriz de correlación que se va a someter a análisis –Pearson o policórica–), el test MAP, el método de HULL (que permite elegir entre diferentes números de factores combinando el principio de parsimonia y la bondad de ajuste del modelo resultante), y finalmente también ofrece la información de los autovalores, para que el usuario pueda representarlos gráficamente y aplicar el scree-test de Cattell, si lo desea. Además, cuando se usan los métodos de estimación de factores ML o ULS (en el último caso, sólo con correlaciones policóricas), el programa ofrece distintos índices de bondad de ajuste; entre ellos el estadístico chi-cuadrado, GFI, AGFI, NNFI, CFI, RMSEA y el estimador del parámetro de no-centralidad. Por último, ofrece información descriptiva de la distribución de los residuales.

4) Métodos de rotación de factores y de asignación de ítems

Posibilidades que ofrece: Como SPSS, FACTOR ofrece una variedad de métodos clásicos de rotación ortogonal y oblicua entre los que figuran OBLIMIN DIRECTO, PROMAX Y VARIMAX. FACTOR también incluye el procedimiento OBLIMIN Y VARIMAX PONDERADO. Y otros métodos menos conocidos, como PROMAJ (Trendafilov, 1994). Pero además ofrece otros métodos nuevos y originales como SIMPLIMAX (Kiers, 1994) y PROMIN (Lorenzo-Seva, 1999). SIMPLIMAX es eficiente pero un método difícil de usar, porque requiere del investigador ciertas especificaciones (ver Ferrando y Lorenzo-Seva, 2014). PROMIN es un caso especial de SIMPLIMAX que no requiere especificaciones previas. Como explican Ferrando y Lorenzo-Seva (2014), PROMIN toma las decisiones difíciles en la propuesta del modelo de modo que está muy cerca del polo exploratorio en que sólo se tiene que especificar el número de factores. Es tan sencillo como los métodos clásicos.

FACTOR también permite una aproximación más confirmatoria dentro del AFE. Entre las opciones posibles, la “rotación pro-custeana semi-especificada” permite proponer una matriz diana en la que se especifica el valor de los elementos que se espera que sean cero en el patrón factorial rotado (Browne, 1972a, 1972b). Esta matriz diana guía la rotación de la matriz de saturaciones factoriales sin imponer el tradicional y menos realista principio de simplicidad factorial (Kaiser, 1974).

Limitaciones: FACTOR ofrece más de 25 rotaciones diferentes, algunas novedosas o muy poco conocidas. ¿Cuál elegir? FACTOR no dispone de un manual de uso “al uso”. El investigador aplicado agradecería algunas recomendaciones sobre cuándo usar un método de rotación u otro.

FACTOR es un programa específicamente desarrollado para cubrir las necesidades del investigador novel, medio y avanzado en materia de Análisis Factorial. En este breve resumen solo hemos dado idea de los aspectos más básicos, dejando para el lector interesado las opciones de hacer análisis factorial de segundo orden, o de probar las soluciones factoriales intermedias entre el análisis factorial confirmatorio y el exploratorio. También cabe destacar que la versión 9.2. de FACTOR (Lorenzo-Seva y Ferrando, 2013) permite evaluar otras aproximaciones no lineales mediante la Teoría de Respuesta a los Ítems (TRI).

En resumen, FACTOR permite múltiples opciones o combinaciones adecuadas, siempre partiendo de que ofrece de forma automática: 1) criterios para evaluar la adecuación de los datos al análisis factorial, y 2) criterios para evaluar la normalidad multivariada y univariada de los datos. Además, FACTOR es un programa que se está mejorando constantemente. La versión en curso, 10.4.01, incluirá las siguientes novedades: 1) estimación de factores mediante el método de estimación de mínimos cuadrados diagonalmente ponderados (DWLS); 2) estimación robusta para ULS y DWLS; 3) revisión de los métodos de estimación del ML para evitar problemas de convergencia; 4) estimación bayesiana de las matrices de correlación tetracórica y policórica; y 5) la posibilidad de obtener errores estándar e intervalos de confianza para todos los parámetros estimados mediante procedimientos de bootstrap-ping.

PRELIS (PRE-procesador de LISREL)

PreliS, el pre-procesador de LISREL, permite realizar un Análisis Factorial Ordinal, que es un análisis factorial no lineal que usa el método de información completa. En lugar de analizar la matriz de correlaciones policóricas, los métodos de información completa utilizan toda la información contenida en el patrón de frecuencias de las categorías de respuesta para obtener las estimaciones de los parámetros (Bock, Gibbons, y Muraki, 1988). Sin embargo, en este trabajo nos centramos únicamente en la aplicación del análisis factorial clásico, objeto de revisión en Lloret et al. (2014). En esta revisión se ha utilizado la versión 9.10 de LISREL, y se remarcarán algunas diferencias con versiones anteriores de LISREL.

1) Modelo factorial. Tipo de datos y matriz de asociación

Posibilidades que ofrece: Cuando los datos se definen como continuos, PRELIS basa los análisis en la matriz de correlaciones de Pearson. Cuando los datos son definidos como ordinales, PRELIS basa los análisis en las matrices de correlaciones policóricas o tetracóricas, dependiendo de si los datos son politómicos o dicotómicos, respectivamente. También se pueden analizar las correspondientes matrices de varianzas-covarianzas. Esta es la opción que aparece por defecto, aunque si los datos están definidos como ordinales y se emplea como método de estimación MINRES (MINimum RESiduals), equivalente a ULS (ver siguiente apartado), siempre se emplea como input la matriz de correlaciones policóricas (o tetracóricas), independientemente de que en las opciones se marque la matriz de covarianzas o de correlaciones (para trabajar con las matrices de varianzas-covarianzas, ver Jöreskog, 2002).

Si los datos están definidos como continuos, el programa ofrece información de la media y la desviación típica de los ítems, así como de la asimetría y curtosis. También de forma automática realiza contrastes de normalidad univariados, y ofrece la opción de realizar un contraste de normalidad multivariada, mediante la prueba de Mardia (1970). En el caso de emplear ML como método de estimación, cuando existe multicolinealidad severa para alguna de las variables, el programa lo indica.

Si los datos están definidos como ordinales, el programa ofrece los umbrales entre categorías de respuesta, así como pruebas de adecuación de la estimación de cada correlación bivariada, con el fin de evaluar si las variables latentes que subyacen a los ítems ordinales siguen una distribución normal.

Así pues, PRELIS ofrece al investigador un análisis preliminar y automático de las distribuciones de los ítems.

Limitaciones: PRELIS no ofrece información sobre la adecuación de la matriz para su factorización mediante la medida KMO ni la Prueba de Esfericidad de Bartlett.

2) Métodos de estimación de factores

Posibilidades que ofrece: Además del método componentes principales (CP), que sabemos no es un método de factorización propiamente dicho, PRELIS tiene dos métodos de estimación: ML y MINRES. Este último método, propuesto por Harman (1980), es equivalente a mínimos cuadrados no ponderados (ULS) excepto por una transformación ortogonal de las saturaciones factoriales (Jöreskog, 2003). Cabe destacar que en la versión 9.10 de LISREL, el análisis CP no aparece como un método de estimación dentro del análisis factorial exploratorio, como sucedía en versiones anteriores, sino que aparece como un análisis diferenciado.

Limitaciones: como en FACTOR, no dispone de métodos de estimación de máxima verosimilitud robusta, ni de mínimos cuadrados ponderados.

3) Método de selección de factores

Posibilidades que ofrece: En versiones anteriores de LISREL, el método concreto de selección de factores dependía del método de estimación empleado. Cuando se empleaba ML, el programa ajustaba modelos con diferentes números de factores (0, 1, 2, etc.) y

ofrecía índices de bondad de ajuste para los distintos modelos. En concreto, pruebas de chi-cuadrado para cada modelo, el índice de RMSEA (*Root Mean Square Error of Approximation*), también para cada modelo, y la significación de las diferencias en chi-cuadrado entre modelos consecutivos. El criterio de parada en versiones anteriores de LISREL (8.30 y 8.80) tiene en cuenta varias posibles contingencias. Si no se puede rechazar la hipótesis nula de que el modelo con cero factores ajusta a los datos, no tendría sentido continuar con los análisis, ya que las variables analizadas serían linealmente independientes, por lo que el programa se interrumpe.

Si el modelo con cero factores no ajusta a los datos, el programa continúa incrementando en uno el número de factores. Si la probabilidad asociada a un modelo, con un determinado número de factores k , es mayor que .10, el programa considera que ese modelo representa adecuadamente los datos y ofrece la solución para dicho modelo. Si la probabilidad asociada a un modelo es menor que .10, pero las diferencias en el ajuste de dos modelos con un número consecutivo de factores es mayor que .10, el programa se interrumpe, ya que considera que la diferencia entre dichos modelos no es suficientemente grande como para extraer un factor más, imprimiendo la solución del modelo más parsimonioso, con menor número de factores.

Finalmente si el valor de RMSEA para un determinado modelo con k factores es menor que .05, el programa imprime la solución del modelo con dicho número de factores. Este último criterio, según Jöreskog, Sörbom, Du Toit y Du Doit (1999) intenta garantizar que no se sobreestime el número de factores en muestras grandes (Browne y Cudeck, 1993). Si no se cumple ninguna de las condiciones anteriores, el programa incrementa k (número de factores) en 1, y continúa el proceso hasta que se cumplan algunas de las condiciones anteriores.

Sin embargo, en el PRELIS de LISREL 9.10, el criterio que se sigue para mantener un determinado número de factores k , independientemente del método de estimación empleado, es el criterio de Kaiser. Así pues, el número de factores mantenidos será igual al número de autovalores en la matriz de correlaciones mayor que 1. Sin embargo, cuando se emplea máxima verosimilitud (ML) con datos continuos, el programa sigue imprimiendo la tabla de decisión que se imprimía en versiones anteriores, con los índices de bondad de ajuste de los distintos modelos (y su comparación), desde 0 factores hasta el número sugerido por la regla de Kaiser. Esta información puede ser evaluada por el usuario para determinar si un número menor de factores podría resultar suficiente para representar satisfactoriamente los datos. También en principio parece que es posible fijar el número de factores teóricamente esperado. Sin embargo, si el número de factores que se solicitan es diferente del número que se extrae siguiendo el criterio de Kaiser, el programa no llega a imprimir una solución.

Limitaciones: PRELIS no ofrece ninguna información ni criterio adicional como el análisis paralelo (PA) o MAP, tampoco una variedad de índices de bondad de ajuste, ni el gráfico de sedimentación o scree-test (aunque se puede obtener a partir de los autovalores).

4) Métodos de rotación de factores y de asignación de ítems

Posibilidades que ofrece: Con ambos métodos de estimación (ML y MINRES) se ofrecen las siguientes soluciones: 1) NO rotada, 2) con rotación ortogonal, en concreto VARIMAX (Kaiser, 1958), 3) con rotación oblicua, en concreto PROMAX (Hendrickson y White, 1964), y 4) la solución de variables referente, que también ofrece las correlaciones entre factores. Esta última solución se obtiene mediante el método de estimación TSLS (*Two-Stage Least Squares*; ver Jöreskog et al., 1999) y se elige como referente el ítem del factor con la mayor saturación según la solución con rotación PROMAX. La ventaja de evaluar la solución obtenida mediante este último método es que se pueden obtener estimaciones de los errores típicos de estimación y los valores t asociados a las saturaciones factoriales, excepto para aquéllos ítems empleados como referente. Por lo tanto, es posible determinar si las estimaciones de los parámetros son estadísticamente significativas. Si se desea estimar la solución de variables referente mediante ML, es posible emplear comandos concretos (ver los ejemplos de sintaxis que se ofrecen en el manual). En este último caso se aconseja emplear la matriz de varianzas-covarianzas como input, con el fin de obtener errores típicos correctos (ver Jöreskog et al., 1999).

En resumen, PRELIS permite utilizar diferentes matrices input en función de la naturaleza de los datos y del modelo más adecuado, pero está absolutamente limitado en cuanto a los métodos de selección de factores, y tiene pocos métodos de estimación (sólo ML y MINRES) y de rotación (VARIMAX en ortogonal y PROMAX en oblicua).

MPlus

1) Modelo factorial. Tipo de datos y matriz de asociación

Posibilidades que ofrece: MPlus ofrece diferentes posibilidades, permitiendo analizar la matriz adecuada en función de la naturaleza de los datos. Si no se indica nada en el fichero de instrucciones, el programa asume que los datos son continuos; si son ordinales o categóricos hay que indicarlo con la instrucción correspondiente. Para ítems continuos estimará la matriz de correlaciones de Pearson; para ítems politómicos ordinales estimará la matriz de correlaciones policóricas; y para datos dicotómicos estimará la matriz de correlaciones tetracóricas. Si el investigador considera que sus datos ordinales pueden ser modelados de forma más robusta y simple empleando el modelo lineal, entonces tendrá que definirlos como continuos, al igual que sucede con PRELIS.

En el caso de ítems categóricos, el programa ofrece de forma preliminar información para cada ítem sobre la distribución de los sujetos en las diferentes categorías de respuesta. Concretamente, ofrece el porcentaje y número de sujetos que han contestado cada una de las posibles alternativas.

Limitaciones: MPlus no ofrece pruebas de adecuación (como por ejemplo KMO) para evaluar la adecuación de la matriz de correlaciones para su factorización. Y tampoco ofrece de forma preliminar y automática, pruebas para evaluar el ajuste de los datos a la normalidad.

2) Métodos de estimación de factores

Posibilidades que ofrece: MPlus ofrece una extensa variedad de métodos de estimación de factores, y permite emplear algunos de los métodos recomendados.

Cuando los ítems se han definido como continuos, MPlus ofrece cuatro posibles métodos de estimación: ML, ML robusta (MLM, MLMV), y ULS. Respecto a los estimadores robustos de máxima verosimilitud, ambos ofrecen estimaciones robustas de los errores típicos y del estadístico chi-cuadrado. En el caso del MLM el ajuste del estadístico chi-cuadrado se hace respecto a la media, por lo que se ofrece el estadístico chi-cuadrado de Satorra-Bentler (Satorra y Bentler, 2001). En el caso del MLMV el ajuste se hace respecto a la media y la varianza.

Cuando hay al menos un ítem categórico, MPlus ofrece también cuatro posibles métodos de estimación: mínimos cuadrados ponderados (WLS), WLS robustos (WLSM, WLSMV), y ULS. La opción por defecto es WLSMV; y la opción menos recomendable es ULS, que es menos estable y que cuando se combina con la matriz de correlaciones tetracóricas, no ofrece índices de bondad de ajuste (igual que pasa con FACTOR). Al igual que en el caso de los estimadores robustos de máxima verosimilitud, los estimadores robustos de mínimos cuadrados ponderados ofrecen estimaciones robustas de los errores típicos y del estadístico chi-cuadrado, y los nombres de cada estimador hacen referencia a que el ajuste del chi-cuadrado es únicamente respecto a la media (WLSM), o respecto a la media y la varianza (WLSMV).

Por lo tanto, vemos que Mplus ofrece métodos de estimación robustos a la violación del supuesto de normalidad multivariada, como son por ejemplo WLS, WLS Robustos (WLSM, WLSMV), o ML Robusta (MLM, MLMV). La elección de uno u otro dependerá del tipo de matriz que resulte más adecuada como input, en función del tipo de ítems.

3) Método de selección de factores

Posibilidades que ofrece: MPlus ofrece métodos basados en la minimización de los residuales. Concretamente, ofrece el RMSEA y el SRMR (*Standardized Root Mean Square Residual*).

Este programa requiere que el investigador fije el número de factores esperado, y el output ofrece el resultado de los diferentes modelos puestos a prueba, desde ajustar una solución de un único factor, hasta una solución con el número de factores especificado, que como máximo es 9. Por lo tanto, permite comparar el ajuste de los modelos alternativos en función de sus índices de bondad de ajuste. Dicha comparación se puede realizar en base a los índices de ajuste incrementales (Δ RMSEA, Δ CFI y Δ NNFI), siguiendo los criterios recomendados en la literatura para interpretar las diferencias en índices de bondad de ajuste (e.g. Chen, 2007; Cheung y Rensvold, 2002; Widaman, 1985).

Limitaciones: No ofrece alguno de los criterios "extra" recomendados, como el PA o el MAP. Solamente emplea la estrategia de comparación de modelos.

4) Métodos de rotación de factores y de asignación de ítems

Posibilidades que ofrece: MPlus ofrece una amplia variedad de métodos de rotación ortogonal y oblicua: VARIMAX, PROMAX, QUARTIMIN, OBLIMIN, GEOMIN, CF-VARIMAX, CF-QUARTIMAX, CRAWFER, CF-EQUAMAX, CF-PARSIMAX, CF-FACPARSIM y TARGET. Todas las rotaciones están disponibles tanto con procedimiento oblicuo como ortogonal, excepto VARIMAX que es ortogonal, y PROMAX y QUARTIMIN que son oblicuas. La rotación por defecto es GEOMIN oblicua.

Tal como se ha expuesto en trabajos recientes (Ferrando y Lorenzo-Seva, 2014), el método de rotación utilizado determina en cierto modo la naturaleza más exploratoria o confirmatoria del análisis realizado. Concretamente, la rotación Target disponible en MPlus permite una aproximación más confirmatoria bajo la etiqueta de análisis factorial exploratorio. Esta rotación permite proponer una matriz diana en la que se especifica el valor de algunos de sus elementos, concretamente aquellos que se espera que sean cero en el patrón factorial rotado. Dicha matriz diana guía por tanto la rotación de la matriz de saturaciones factoriales. Una descripción más detallada de los criterios seguidos cuando se aplica este método de rotación ha sido expuesta en el trabajo de Ferrando y Lorenzo-Seva (2014) bajo el nombre de "rotación procusteana semi-especificada", y puede ser también consultada en el trabajo de Browne (2001) con el nombre "rotation to a partially specified target". Por otra parte, la asignación de ítems a los factores depende del investigador, que aplicará los criterios recomendados para determinar qué ítems pertenecen a cada factor.

Limitaciones: En Mplus al igual que en FACTOR, el investigador aplicado se puede ver abrumado por la gran cantidad de opciones de rotación que ofrece el programa, y necesitar algunas recomendaciones sobre cuándo usar un método de rotación u otro.

En resumen, MPlus puede ser usado de manera eficiente ya que ofrece amplias posibilidades, aunque no por eso está exento de alguna limitación -básicamente relacionada con los criterios de selección de factores-.