

INTRODUCCIÓN AL META-ANÁLISIS MULTIVARIADO CON MODELOS DE ECUACIONES ESTRUCTURALES

INTRODUCTION TO META-ANALYTIC STRUCTURAL EQUATION MODELING

JOSÉ ANTONIO LÓPEZ-LÓPEZ¹,
RAIMUNDO AGUAYO-ESTREMER², LAURA BADENES-RIBERA³
Y BELÉN FERNÁNDEZ-CASTILLA⁴

Cómo referenciar este artículo/How to reference this article:

López-López, J. A., Aguayo-Estremera, R., Badenes-Ribera, L. y Fernández-Castilla, B. (2025). Introducción al meta-análisis multivariado con Modelos de Ecuaciones Estructurales [Introduction to Meta-Analytic Structural Equation Modeling]. *Acción Psicológica*, 22(1), 23–40. <https://doi.org/10.5944/ap.22.1.43279>

Resumen

El meta-análisis con modelos de ecuaciones estructurales (*Meta-Analytic Structural Equation Modeling*, MASEM) es una metodología novedosa de síntesis de la evidencia que combina las ventajas del meta-análisis tradicional con

los modelos de ecuaciones estructurales, permitiendo explorar relaciones complejas entre variables a través de la integración de estudios independientes. Este tutorial ofrece una introducción accesible a la metodología MASEM, incluyendo los conceptos fundamentales, los pasos metodológicos para su implementación, y una aplicación práctica usando software estadístico libre. El

Correspondence address [Dirección para correspondencia]: José Antonio López López, Facultad de Psicología y Logopedia, Universidad de Murcia, España.

Email: josealopezlopez@um.es

ORCID: José Antonio López López (<https://orcid.org/0000-0002-9655-3616>), Raimundo Aguayo-Estremera (<https://orcid.org/0000-0001-7276-9394>), Laura Badenes-Ribera (<https://orcid.org/0000-0002-4706-690X>) y Belén Fernández-Castilla (<https://orcid.org/0000-0002-3451-0637>).

¹ Universidad de Murcia, España.

² Universidad Complutense de Madrid, España.

³ Universitat de València, España.

⁴ Universidad Nacional de Educación a Distancia, España.

Recibido: 5 de noviembre de 2024

Aceptado: 25 de febrero de 2025

objetivo es proporcionar a los investigadores una comprensión sólida y las herramientas necesarias para aplicar MASEM en sus propios estudios. Para ello se aborda desde la preparación de datos hasta la interpretación de resultados, destacando tanto las fortalezas como las limitaciones de esta metodología.

Palabras clave: MASEM; Meta-análisis; Modelos de ecuaciones estructurales; Síntesis de la evidencia.

Abstract

Meta-Analytic Structural Equation Modeling (MASEM) is a novel methodology for evidence synthesis which combines the advantages of traditional meta-analysis and structural equation modeling, allowing the exploration of complex relationships among variables through the integration of independent studies. The present tutorial offers an accessible introduction to the MASEM methodology, including the key concepts involved, methodological steps for implementation, and a practical example using free statistical software. The goal is to provide researchers with a solid understanding and with the necessary tools to apply MASEM techniques to their own studies. To that aim, the process from data preparation to results interpretation is covered, highlighting the strengths and limitations of this methodology.

Keywords: MASEM; Meta-analysis; Structural equation models; Evidence synthesis.

Introducción

El incremento masivo de artículos científicos publicados cada año plantea desafíos para el seguimiento de los desarrollos y avances en áreas específicas del conocimiento. Para enfrentar esta sobrecarga de información, en la década de 1970 surgieron diversas técnicas diseñadas para sintetizar la evidencia científica acumulada en un

campo de investigación determinado. Entre ellas, destaca el meta-análisis (Glass, 1976), definido como un conjunto de métodos estadísticos que permiten combinar de forma cuantitativa los resultados de estudios que investigan cuestiones similares, con el fin de generar conclusiones más robustas y precisas (Cooper et al., 2019).

La mayoría de los meta-análisis publicados hasta la fecha en Psicología se han centrado en sintetizar la evidencia disponible sobre la asociación entre dos variables. Por ejemplo, Hattie (2009) realizó una meta-revisión de más de 800 meta-análisis que estudiaban la relación bivariada entre diversas características (de los estudiantes, de los profesores, de las políticas) y el rendimiento académico. Sin embargo, muchas preguntas de investigación en Psicología son multivariantes, es decir, involucran la comprensión de cómo múltiples variables interactúan de forma compleja para influir en un determinado resultado. Por ejemplo, ¿cómo interactúan conjuntamente las características familiares, contextuales y del estudiante para determinar el rendimiento académico?

Los enfoques tradicionales de meta-análisis no permiten responder a preguntas de investigación de naturaleza multivariante. Para superar esta limitación, Becker (1992, 1995; ver también Becker y Aloe, 2019) propuso un enfoque meta-analítico basado en modelos, es decir, yendo más allá de las asociaciones bivariadas. Este enfoque permite la evaluación de teorías, y con ello ofrece una comprensión más profunda de fenómenos complejos, algo fundamental para el avance del conocimiento científico en Psicología y ciencias afines.

Una metodología clave en este contexto es el meta-análisis de modelos de ecuaciones estructurales (en inglés, *Meta-Analytic Structural Equation Modeling*, MASEM), el cual ha ido ganando relevancia a lo largo de las últimas décadas (Cheung, 2015, 2019; Cheung y Chan, 2005; Jak, 2015; Viswesvaran y Ones, 1995). Debido a su creciente importancia y a su gran potencial para la investigación psicológica, el objetivo de este trabajo es ofrecer una introducción accesible en español al MASEM, así como proporcionar herramientas para su implementación. Para lectores/as sin experiencia previa con técnicas de meta-análisis univariado, el estudio de las referencias de la siguiente

sección resultará de gran utilidad para comprender las secciones posteriores.

MASEM: encajando las piezas

En meta-análisis, los datos individuales de los estudios no suelen estar disponibles para su integración. En consecuencia, se recurre a indicadores numéricos de la magnitud de la asociación entre las variables de interés, conocidos como tamaños del efecto (v.g., correlación de Pearson), que pueden calcularse fácilmente a partir de la información disponible en los estudios primarios (Grissom y Kim, 2012).

A la hora de combinar los tamaños del efecto en el meta-análisis, existen dos tipos principales de modelos, efectos fijos y efectos aleatorios (Hedges y Vevea, 1998). Por un lado, el modelo de efectos fijos (*fixed-effects model*) asume que los tamaños del efecto varían entre estudios debido únicamente a que las muestras utilizadas son diferentes. El modelo de efectos aleatorios (*random-effects model*), en cambio, asume que la variabilidad observada entre tamaños del efecto no se debe únicamente a la diferencia entre muestras (variabilidad muestral) sino también a la diferencia entre las características de los estudios (variabilidad inter-estudios). El uso de un modelo u otro dependerá de consideraciones teóricas (*¿realmente puedo considerar estos estudios como réplicas?*) y/o empíricas (*¿se observa tanta variabilidad inter-estudios como para concluir que los estudios provienen de poblaciones diferentes?*), así como del grado de generalización que se persigue (estrictamente, solo el modelo de efectos aleatorios permite generalizar las conclusiones más allá de la muestra de estudios incluidos, que se asume que representan una muestra razonablemente representativa de una población más amplia). Además, el modelo de efectos aleatorios implica una mayor complejidad, por lo que no es aconsejable para aplicaciones con muy pocos estudios. Para ampliar información sobre meta-análisis, recomendamos los manuales de Cooper et al. (2019) y Botella y Sánchez-Meca (2015).

Por otra parte, los modelos de ecuaciones estructurales (*Structural Equation Modeling*, SEM) constituyen un conjunto de técnicas estadísticas que facilitan la evaluación de las interrelaciones entre variables, ya hayan sido éstas directamente observadas o se hayan construido a partir de un conjunto de variables observadas (variables latentes). A diferencia de los métodos tradicionales como la regresión múltiple, que tiende a modelar relaciones unidireccionales y analizar constructos de forma independiente, los modelos SEM permiten modelar múltiples relaciones simultáneamente, lo que los hace útiles para evaluar modelos teóricos más complejos. También constituyen una potente herramienta en la investigación psicométrica, donde una de sus aplicaciones más comunes es el análisis factorial confirmatorio, utilizado para evaluar la estructura interna de un test o cuestionario.

El punto de partida para ajustar un modelo SEM es la matriz de varianzas-covarianzas de los datos y el tamaño muestral. Una vez se ajusta el modelo deseado propuesto por el/la investigador/a, se obtiene la matriz de varianzas-covarianzas reproducida, es decir, la matriz que se desprendería del modelo estructural propuesto. El ajuste del modelo se evalúa en base a las diferencias entre la matriz de varianzas-covarianzas observada y la reproducida, utilizando para ello diversos índices de bondad de ajuste. Cuanto menor es la discrepancia entre estas dos matrices, mejor ajustarían los datos al modelo propuesto. Cuando se aplican como parte de un MASEM, los modelos SEM suelen utilizar matrices de correlaciones no transformadas (cf. Cheung y Chan, 2005) en lugar de matrices de varianzas-covarianzas, ya que las primeras permiten extraer la información en una métrica común para todos los estudios primarios. Para más información, redirigimos al lector a Kline (2023), Lei y Wu (2007), y Ruiz y col. (2010).

La combinación de los modelos SEM con las técnicas meta-analíticas ha culminado en los modelos MASEM, bajo cuyo nombre hay un conjunto de procedimientos creciente que se pueden agrupar en dos categorías generales: enfoques basados en correlaciones y basados en parámetros (ver Tabla 1). La diferencia radica en que, mientras en el primer caso se sintetizan matrices de correlaciones entre variables, en el segundo caso la síntesis se hace con los tamaños del efecto del modelo (e.g., coeficientes de correlación parcial, pesos de regresión, etc.).

Tabla 1

Resumen de los principales procedimientos MASEM

Tipo	Procedimiento	Autores principales	Descripción general
Basado en correlaciones	Two-Stage (TSSEM)	Cheung (2015) Cheung y Chan (2005)	Se sintetizan las matrices de correlaciones de cada estudio primario y luego se ajusta el modelo SEM.
	One-Stage (OSMASEM)	Jak y Cheung (2020)	La síntesis de las matrices de correlaciones y el ajuste se hace en un solo paso.
Basado en parámetros	Two-Stage	Cheung y Cheung (2016)	Primero se ajusta el modelo SEM en cada estudio y luego se sintetizan los parámetros de interés de los modelos resultantes.

Nota. Este resumen no es exhaustivo, ya que existen otros procedimientos que no se abordarán en este manuscrito debido a su uso limitado.

Enfoques MASEM

En esta sección se presentan los principales enfoques metodológicos empleados en la actualidad para el ajuste de modelos MASEM, aplicándolos a un meta-análisis realizado por Cano-López y colaboradores (2022) sobre el modelo metacognitivo de la rumiación y la depresión (Figura 1) propuesto por Papageorgiou y Wells (2003). La base de datos completa, que incluye 15 estudios y las correlaciones entre las variables presentados en Figura 1, puede encontrarse en https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d

MASEM basado en correlaciones en dos etapas (TSSEM)

La primera etapa de este enfoque consiste en combinar meta-analíticamente las matrices de correlaciones entre las variables integrantes del modelo examinado. Para ello, también se extraen los tamaños muestrales de los estudios primarios, con el fin de ponderar cada coeficiente de correlación de acuerdo con su precisión. En una segunda etapa, se ajusta el modelo SEM sobre la matriz combinada obtenida en el paso anterior (Cheung y Chan, 2005). A continuación, explicamos cómo realizar estos análisis utilizando R. En el material suplementario (https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d) también se incluye un tutorial sobre cómo realizar estos análisis utilizando una aplicación web,

Figura 1

Modelo metacognitivo de la rumiación y la depresión (Papageorgiou y Wells, 2003)




Tabla 2

Matrices de correlaciones de los dos primeros estudios analizados

Estudio 1					
	1	2	3	4	5
1. Creencias positivas	1				
2. Creencias negativas (I)	-	1			
3. Creencias negativas (II)	-	-	1		
4. Rumiación	.45	-	-	1	
5. Depresión	.53	-	-	-	1
Estudio 2					
	1	2	3	4	5
1. Creencias positivas	1				
2. Creencias negativas (I)	.21	1			
3. Creencias negativas (II)	.12	.57	1		
4. Rumiación	.58	.51	.39	1	
5. Depresión	.23	.35	.47	.47	1

webMASEM (Jak et al., 2021) que ha sido creada específicamente para aplicar de forma sencilla esta metodología.

En el ejemplo propuesto, comenzamos extrayendo de cada estudio las correlaciones de Pearson entre las cinco variables que conforman el modelo (Tabla 2), así como el tamaño muestral de cada estudio. Encontramos que hay estudios que no incluyen todas las correlaciones de interés, lo cual sucede habitualmente porque no se han estudiado todas las variables del modelo, en cuyo caso se asumen como *variables perdidas* y simplemente se filtran en los análisis MASEM. Un escenario diferente es el de las *correlaciones perdidas*, que se produce cuando los autores no reportan en el manuscrito alguna de estas correlaciones por no ser de su interés (este es el caso de estudio 1 de la Tabla 2, donde los autores no reportan la correlación entre rumiación y depresión a pesar de que ambas variables se habían estudiado). Este segundo escenario sí es problemático cuando se aplica un modelo de efectos fijos (cf. Jak y Cheung, 2018a), en cuyo caso habrá que considerar como perdida aquella variable de la que no se reportan todas sus correlaciones.

Una vez se han extraído las correlaciones y sus tamaños muestrales, éstas se combinan utilizando técnicas de meta-análisis multivariado para obtener una matriz de correlaciones combinada. Becker (1992) propuso inicialmente realizar esta combinación de matrices utilizando el

método de estimación por *Mínimos Cuadrados Generalizados*. Sin embargo, en MASEM se realiza esta combinación utilizando modelos SEM. En caso de aplicar un modelo de efectos fijos, la matriz de correlaciones combinada se obtendría tras realizar un análisis multigrupo (Cheung y Chan, 2005). Si por el contrario se desea aplicar un modelo de efectos aleatorios, se emplean otras técnicas más complejas, cuyos detalles se pueden consultar en Cheung (2013). Como ya se ha mencionado, la decisión de ajustar un modelo u otro dependerá de consideraciones teóricas y/o prácticas.

Desde un punto de vista teórico, los estudios que se van a sintetizar en este ejemplo presentan diferencias sustanciales en cuanto a sus características y procedimientos, lo que sugiere la necesidad de aplicar un modelo de efectos aleatorios. No obstante, con fines didácticos, iniciamos el análisis utilizando un modelo de efectos fijos, con el objetivo de ilustrar cómo evaluar su ajuste y determinar, desde una perspectiva empírica, si es el modelo más adecuado para estos datos.

Para ajustar cualquiera de los modelos, se utiliza la función `tssem1` del paquete *metaSEM*. En el código de R (disponible en https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d), se explica paso a paso cómo preprocesar los datos para obtener los objetos que se utilizan en los

próximos comandos, que son la lista de matrices de correlaciones (`corr_lista$data`) y los tamaños muestrales (`corr_lista$n`). Este código también incluye los comandos para eliminar las variables que contienen correlaciones perdidas, paso que sólo es necesario en el caso de aplicar un modelo de efectos fijos¹. Además, tenemos que indicar qué modelo queremos ajustar indicándolo en el comando `method`, donde "FEM" se referirá a un modelo de efectos fijos.

```
paso1_EF <- tssem1(Cov=corr_lista$data,
n=corr_lista$n, method="FEM")
```

Después de realizar los análisis, podemos imprimir los resultados (Figura 2) con el comando `summary(paso1_EF)`.

En los resultados, primero se observan las correlaciones combinadas en forma de vector. Antes de interpretarlas, es crucial evaluar el ajuste del modelo para determinar si es adecuado aplicar un modelo de efectos fijos. Un test χ^2 significativo ($\chi^2 = 212.46$, $p < .001$) indica que no podemos asumir que todas las correlaciones provienen de una misma población, lo que sugiere heterogeneidad entre los estudios. Según Hu y Bentler (1999), un RMSEA $< .06$ y un CFI $> .95$ indican un buen ajuste. En este caso, el CFI cumple (.965), pero el RMSEA es superior (.094), lo que

Figura 2

Resultados al ejecutar el comando `summary` (`paso1_EF`)

```
Coefficients:
      Estimate Std. Error z value      Pr(>|z|)
S[1,2] 0.413571  0.013835 29.8933 < 0.00000000000000022 ***
S[1,3] 0.235075  0.020082 11.7055 < 0.00000000000000022 ***
S[1,4] 0.141243  0.017255  8.1854 0.00000000000000022 ***
S[1,5] 0.262661  0.014847 17.6908 < 0.00000000000000022 ***
S[2,3] 0.560036  0.015706 35.6582 < 0.00000000000000022 ***
S[2,4] 0.420090  0.014667 28.6424 < 0.00000000000000022 ***
S[2,5] 0.603027  0.011066 54.4950 < 0.00000000000000022 ***
S[3,4] 0.622322  0.014298 43.5260 < 0.00000000000000022 ***
S[3,5] 0.549116  0.015895 34.5473 < 0.00000000000000022 ***
S[4,5] 0.466001  0.013482 34.5650 < 0.00000000000000022 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Goodness-of-fit indices:
              Value
Sample size      4384.0000
Chi-square of target model      212.4604
DF of target model      59.0000
p value of target model      0.0000
Chi-square of independence model 4441.1329
DF of independence model      69.0000
RMSEA      0.0943
RMSEA lower 95% CI      0.0810
RMSEA upper 95% CI      0.1084
SRMR      0.0702
TLI      0.9590
CFI      0.9649
AIC      94.4604
BIC     -282.2969
OpenMx status1: 0 ("0" or "1": The optimization is considered fine.
Other values may indicate problems.)
```

¹ Este código ha sido adaptado del manual de Jak (2015).

sugiere que el ajuste es cuestionable. Por lo tanto, los datos empíricos también invitan al ajuste de un modelo de efectos aleatorios.

Para ajustar un modelo de efectos aleatorios, utilizamos la misma función, modificando el método a REM. En caso de contar con un número reducido de estudios, como ocurre en este ejemplo, es recomendable emplear el comando `RE.type = "Diag"`, que supone asumir que los elementos fuera de la diagonal principal de varianzas son 0, y por lo tanto que los efectos aleatorios de las diferentes

correlaciones no covarían entre sí. A pesar de que esta suposición puede no ser del todo realista, si el número de estudios es limitado, podría no ser viable estimar esas covarianzas² (Cheung y Cheung, 2016). El código quedaría de la siguiente manera:

```
paso1_EA <- tssem1(cons_lista$data,
cons_lista$n, method="REM", RE.type = "Diag")
```

Y para obtener los resultados (Figura 3), ejecutaríamos `summary(paso1_EA)`.

Figura 3.

Resultados al ejecutar el comando `summary(paso1_EA)`

95% confidence intervals: z statistic approximation (robust=FALSE)

Coefficients:

	Estimate	Std. Error	lbound	ubound	z value	Pr(> z)	
Intercept1	0.2611863348	0.0212227845	0.2195904416	0.3027822281	12.3069	< 0.0000000000000002	***
Intercept2	0.1567363798	0.0288480609	0.1001952193	0.2132775402	5.4332	0.0000005536	***
Intercept3	0.4285081680	0.0258720939	0.3777997957	0.4792165403	16.5626	< 0.0000000000000002	***
Intercept4	0.2609284719	0.0145639321	0.2323836895	0.2894732542	17.9161	< 0.0000000000000002	***
Intercept5	0.6162826120	0.0269296426	0.5635014825	0.6690637416	22.8849	< 0.0000000000000002	***
Intercept6	0.5144631575	0.0390984300	0.4378316428	0.5910946722	13.1582	< 0.0000000000000002	***
Intercept7	0.4725051065	0.0401927328	0.3937287978	0.5512814152	11.7560	< 0.0000000000000002	***
Intercept8	0.4091792592	0.0380579682	0.3345870121	0.4837715063	10.7515	< 0.0000000000000002	***
Intercept9	0.4262195324	0.0360221352	0.3556174447	0.4968216201	11.8322	< 0.0000000000000002	***
Intercept10	0.5408788265	0.0349964957	0.4722869553	0.6094706978	15.4552	< 0.0000000000000002	***
Tau2_1_1	0.0007122902	0.0010232222	-0.0012931884	0.0027177689	0.6961	0.48635	
Tau2_2_2	0.0011059318	0.0019908969	-0.0027961545	0.0050080181	0.5555	0.57856	
Tau2_3_3	0.0052921247	0.0031097589	-0.0008028908	0.0113871401	1.7018	0.08880	.
Tau2_4_4	0.0000000001	NA	NA	NA	NA	NA	
Tau2_5_5	0.0000000001	0.0012646191	-0.0024786079	0.0024786081	0.0000	1.00000	
Tau2_6_6	0.0075913677	0.0066750271	-0.0054914450	0.0206741803	1.1373	0.25542	
Tau2_7_7	0.0099851791	0.0063484168	-0.0024574892	0.0224278475	1.5729	0.11575	
Tau2_8_8	0.0005353539	0.0036079540	-0.0065361061	0.0076068138	0.1484	0.88204	
Tau2_9_9	0.0051328840	0.0053905891	-0.0054324764	0.0156982445	0.9522	0.34100	
Tau2_10_10	0.0088863969	0.0053646502	-0.0016281244	0.0194009181	1.6565	0.09763	.

Q statistic on the homogeneity of effect sizes: 301.8551

Degrees of freedom of the Q statistic: 72

P value of the Q statistic: 0

Heterogeneity indices (based on the estimated Tau2):

	Estimate
Intercept1: I2 (Q statistic)	0.1797
Intercept2: I2 (Q statistic)	0.2335
Intercept3: I2 (Q statistic)	0.6690
Intercept4: I2 (Q statistic)	0.0000
Intercept5: I2 (Q statistic)	0.0000
Intercept6: I2 (Q statistic)	0.8132
Intercept7: I2 (Q statistic)	0.8375
Intercept8: I2 (Q statistic)	0.1716
Intercept9: I2 (Q statistic)	0.6848
Intercept10: I2 (Q statistic)	0.8470

Number of studies (or clusters): 15

Number of observed statistics: 82

Number of estimated parameters: 20

Degrees of freedom: 62

-2 log likelihood: -178.1773

openMx status1: 6 ("0" or "1": The optimization is considered fine.

Other values may indicate problems.)

² Si hay un número de estudios sustancial, se puede utilizar el comando `RE.type = "Symm"` para estimar estas covarianzas.

Tabla 3

Matriz de correlación combinada, que se utilizará para ajustar un modelo SEM en la etapa 2. Entre paréntesis aparece el valor del estadístico I^2

Estudio 1	1	2	3	4	5
1. Creencias positivas	1				
2. Creencias negativas (I)	.26 (18%)	1			
3. Creencias negativas (II)	.16 (23%)	.62 (0%)	1		
4. Rumiación	.43 (67%)	.51 (81%)	.41 (17%)	1	
5. Depresión	.26 (0%)	.47 (84%)	.43 (68%)	.54 (85%)	1

En los resultados, observamos que no sólo se imprime el vector que contiene las correlaciones combinadas en las líneas que comienzan con la palabra *Intercept* (en la Tabla 3 se incluyen estas correlaciones en forma de matriz), sino también un vector con las varianzas inter-estudios de estas correlaciones (τ^2). Para poder evaluar la magnitud de τ^2 con respecto a la varianza total de cada correlación, podemos revisar los valores de los estadísticos I^2 , que nos indicarían el porcentaje de la variabilidad total que se debe a heterogeneidad entre estudios (Higgins y Thompson, 2002). Es importante interpretar el índice I^2 en términos relativos (Borenstein et al., 2017).

Como puede verse en la Tabla 3, las correlaciones más altas las encontramos entre creencias negativas (I) y creencias negativas (II), seguido de rumiación y depresión. Las correlaciones combinadas en las que se observa un mayor porcentaje de variabilidad debido a heterogeneidad entre estudios son las correlaciones entre rumiación y depresión. En esta fase, también se estima la matriz de varianzas-covarianzas de las correlaciones de la Tabla 2, que puede obtenerse mediante el comando `vcov(paso1_EA)`. Esta es la matriz que se utilizará en el paso 2 para asignar pesos a las correlaciones en función de su precisión. La precisión de estas correlaciones depende del número de estudios, el tamaño muestral, y su heterogeneidad.

A continuación, podemos ejecutar el paso 2, consistente en ajustar el modelo SEM deseado sobre nuestra matriz de correlaciones combinada. Para especificarlo, empleamos el modelo de acción reticular (*Reticular Action Model*; McArdle y McDonald 1984), que implica la creación de tres matrices: En la matriz A se definen todos los coeficientes de regresión que se desean estimar, en la ma-

triz S se establecen las varianzas (que también han de estimarse), y, por último, si el modelo incluye variables latentes, se tendrían que especificar en la matriz F. El código de R disponible en el material suplementario incorpora más instrucciones sobre cómo crear estas matrices.

Una vez creadas, podemos utilizar la función `tssem2` para obtener las estimaciones de los parámetros del modelo SEM. Al aplicar la función `tssem2`, aparte de indicar nuestra matriz A y S, también hay otros dos comandos a los que atender. El primero es `diag.constraints = TRUE`, el cual garantiza que, al ajustar el modelo, se tenga en cuenta que la diagonal de la matriz de correlaciones combinada está compuesta exclusivamente por 1s. El segundo comando, `intervals = "LB"`, se refiere al método utilizado para obtener los intervalos de confianza. En este caso hemos seleccionado intervalos basados en verosimilitud (*likelihood-based intervals*) ya que tienen un rendimiento superior a los intervalos de confianza tradicionales basados en los errores típicos (cf. Cheung, 2009), y además son el único método aplicable cuando `diag.constraints=TRUE`.

```
paso2_EA <- tssem2(cons_re, Amatrix = A,
  Smatrix = S, diag.constraints=TRUE, intervals
  = "LB")
```

Para obtener los resultados (Figura 4), ejecutamos el siguiente comando: `summary(paso2_EA)`³

Al igual que en el paso 1, antes de explorar las estimaciones del modelo debemos valorar su ajuste. Se puede observar que tanto el RMSEA como en CFI están dentro de los límites recomendados por Hu y Bentler (1999), por lo que el ajuste del modelo propuesto parece adecuado. Por lo tanto, podemos explorar las estimaciones del modelo (ver Figura 1). A excepción de la relación entre creencias

negativas (I) y depresión, el resto de las estimaciones son estadísticamente significativas.

En MASEM, también podemos valorar la significación de los efectos indirectos entre variables, como por ejemplo la influencia indirecta de creencias positivas (PB) sobre creencias negativas I (NBI) a través de la variable rumiación (R). Para ello, dentro del comando `tssem2`, debemos especificar qué efecto indirecto queremos estimar, especificando el producto de los efectos directos que lo componen:

Figura 4

Resultados al ejecutar el comando `summary(paso2_EA)`

95% confidence intervals: Likelihood-based statistic							
Coefficients:							
	Estimate	Std.Error	lbound	ubound	z value	Pr(> z)	
NB12DEP	0.138858	NA	-0.026484	0.298862	NA	NA	
NB22DEP	0.171208	NA	0.053039	0.290443	NA	NA	
R2DEP	0.420294	NA	0.332733	0.512465	NA	NA	
R2NB1	0.549981	NA	0.488819	0.611863	NA	NA	
R2NB2	0.418253	NA	0.344577	0.492076	NA	NA	
PB2R	0.447405	NA	0.405899	0.489763	NA	NA	
ErrorVarDEP	0.620617	NA	0.564849	0.672057	NA	NA	
ErrorVarNB1	0.697521	NA	0.625722	0.761266	NA	NA	
CorNB1NB2	0.395774	NA	0.351622	0.438576	NA	NA	
ErrorVarNB2	0.825065	NA	0.757886	0.881301	NA	NA	
ErrorVarR	0.799829	NA	0.760129	0.835208	NA	NA	
Goodness-of-fit indices:							
					Value		
Sample size					4384.0000		
Chi-square of target model					5.1796		
DF of target model					3.0000		
p value of target model					0.1591		
Number of constraints imposed on "Smatrix"					4.0000		
DF manually adjusted					0.0000		
Chi-square of independence model					1445.4738		
DF of independence model					10.0000		
RMSEA					0.0129		
RMSEA lower 95% CI					0.0000		
RMSEA upper 95% CI					0.0311		
SRMR					0.0195		
TLI					0.9949		
CFI					0.9985		
AIC					-0.8204		
BIC					-19.9776		
OpenMx status1: 6 ("0" or "1": The optimization is considered fine. Other values indicate problems.)							

³ Es importante advertir al lector de que cuando se lleva a cabo el paso 2 de MASEM con este ejemplo, se obtiene una advertencia:

Warning message:
In .solve(x = object\$mx.fit@output\$calculatedHessian, parameters = my.name) :
Error in solving the Hessian matrix. Generalized inverse is used. The standard errors may not be trustworthy.

Este mensaje advierte del cambio de método de estimación utilizado para ajustar el modelo, lo cual puede afectar a la precisión de los errores típicos. Puesto que en este caso los intervalos de confianza no están basados en los errores típicos, no supone un gran problema.

```
paso2_EA_ind <- tssem2(paso1_EA, Amatrix=A,
  Smatrix=S,
  diag.constraints=TRUE, intervals="LB",
  mx.algebras=list(Ind=mxAlge-
bra(PB2R*R2NB1,name="Ind")))
```

En este caso, PB2R y R2NB1 son los nombres asignados a las asociaciones bivariadas de interés en la matriz A. Al imprimir los resultados con el comando `summary(paso2_EA_ind)`, aparece la estimación del efecto indirecto (que no es más que el producto de los dos efectos directos, $0.447 * 0.550 = 0.246$) y su intervalo de confianza, a través del cual podemos evaluar su significación estadística (Figura 5):

Figura 5

*Resultados al ejecutar el comando
summary(paso2_EA_ind)*

mxAlgebras objects (and their 95% likelihood-based CIs):
lbound Estimate ubound
Ind[1,1] 0.2137673 0.2460638 0.2794101

En este caso, el efecto indirecto de creencias positivas sobre creencias negativas (0.246) sí que sería estadísticamente diferente de 0 (IC al 95% 0.214, 0.279).

Una fase muy importante en meta-análisis es el análisis de variables moderadoras, es decir, analizar cómo las características de los estudios (e.g., edad media de la muestra) afectan a las estimaciones meta-analíticas. Desafortunadamente, el enfoque TSSEM sólo permite explorar el rol moderador de características cualitativas de los estudios (e.g., tipo de diseño de investigación empleado). Para más información sobre cómo llevar a cabo análisis de moderadores cualitativos (i.e., análisis de subgrupos) dentro de la metodología MASEM, derivamos al lector a Jak, y Cheung (2018b). Para superar esta limitación y permitir la incorporación de variables moderadoras cuantitativas, se ha propuesto el enfoque MASEM en una etapa (OSMASEM; Jak y Cheung, 2020).

OSMASEM: MASEM basado en correlaciones en un solo paso

Mediante este procedimiento, el modelo SEM meta-analítico se ajusta directamente sobre los datos de los estudios primarios (es decir, omitiendo el paso 1 del enfoque anterior). El procedimiento OSMASEM siempre asume un modelo de efectos aleatorios, y una gran ventaja es que permite explorar si las características de los estudios afectan estadísticamente a todos o a algunos parámetros del modelo, ya sean estas variables cualitativas o cuantitativas (Jak y Cheung, 2020). El trabajo de Jak et al. (2021) constituye un excelente tutorial sobre cómo aplicar OSMASEM utilizando una aplicación web diseñada específicamente para ello.

Al aplicar OSMASEM, el modelo se especifica utilizando el lenguaje del paquete lavaan (Rosseel, 2012). Después, se construyen automáticamente las matrices A, S y F. Finalmente, para ajustar el modelo se aplica la función `osmasem`:

```
res_osmasem<-osmasem(model.name="Modelo
metacognición",
  Mmatrix=M, Tmatrix=T, data=input, inter-
vals.type = "LB")
```

El objeto M contiene las matrices A, S y F, la matriz T especifica la estructura de las varianzas inter-estudios de las correlaciones, y el objeto input contiene las correlaciones de los estudios primarios, esta vez en forma de vectores en lugar de matrices. Para obtener los resultados, se puede ejecutar el comando `summary(res_osmasem)` y comprobar así que las estimaciones son muy similares a las que constan en la Figura 1, obtenidas con el procedimiento MASEM basado en correlaciones en dos etapas utilizando un modelo de efectos aleatorios.

En la base de datos que estamos analizando también se incluye la edad media de la muestra utilizada en cada estudio. Podríamos hipotetizar que, por ejemplo, la relación entre rumiación y depresión (que según la Figura 1 es $b = 0.420$) es más fuerte en muestras donde la media de edad es menor. La gran ventaja de OSMASEM es que nos permite contrastar este tipo de hipótesis, aunque los estudios que no reporten información sobre la variable mode-

radora tengan que ser eliminados de los análisis (por ejemplo, el estudio 14).

Derivamos a los lectores al código de R para obtener la explicación sobre cómo añadir un análisis de moderadores en la metodología OSMASEM, y recordamos que, para aquellos que no estén familiarizados con este programa, existe una aplicación web desde la que se pueden realizar estos análisis sin necesidad de utilizar código R (ver Jak et al., 2021). Mostramos a continuación los resultados que se obtienen (Figura 6), fijándonos en la última línea (*matrix A1*) que es la que contiene el efecto de la edad media sobre la relación entre rumiación y depresión ($b = .001$, $p = .999$). En este caso, la variable edad media no estaría moderando el efecto de rumiación sobre depresión.

MASEM basado en parámetros

El MASEM basado en parámetros también consta de dos pasos, aunque diferentes a los descritos en el MASEM basado en correlaciones. En este caso, primero se ajustaría el modelo SEM deseado (e.g., Figura 1) en cada estudio, se extraerían los coeficientes de regresión y sus errores típicos, y en segundo lugar se realizaría un meta-análisis multivariado para obtener finalmente los coeficientes de regresión combinados (Cheung y Cheung, 2016). El principal problema del procedimiento es que no pueden incluirse estudios con variables o correlaciones faltantes. Esto ocurre porque los coeficientes de regresión, como tamaños del efecto parciales, dependen de las variables pre-

sentes en el modelo. Por ejemplo, la relación entre *rumiación y depresión* (Figura 1) varía según la inclusión o no de la variable *creencias positivas*. Si esta variable no está en el modelo, las estimaciones de ese estudio serían incompatibles con las de otro que sí incluya la variable en el modelo.

Esta limitación es importante, ya que, sobre todo en Ciencias Sociales, es muy complicado que todos los estudios incluidos en un meta-análisis analicen exactamente las mismas variables. Mismamente, si quisiéramos aplicar MASEM basado en parámetros sobre la base de datos con la que estamos trabajando, sólo podríamos utilizar cinco estudios. Aunque la aplicación de este procedimiento es muy limitada, también cuenta con algunas ventajas, como por ejemplo que el análisis de moderadores (ya sean variables cualitativas o cuantitativas) se puede hacer directamente sobre los parámetros de los modelos extraídos en cada estudio.

MASEM psicométrico

En términos generales, se puede decir que la Psicometría se ocupa de la medición de lo psicológico. Sin embargo, a diferencia de otros procedimientos, lo característico de la Psicometría es su énfasis en las propiedades métricas exigibles a las mediciones psicológicas (Muñiz, 2018). Por ejemplo, características como la fiabilidad y la validez son requisitos que toda evaluación psicológica ha de cumplir. Dado que existen muchos estudios primarios que analizan estas propiedades, se pueden realizar estudios

Figura 6

Resultados al ejecutar el comando `summary(osmasem_edad)`

free parameters:							
	name	matrix	row	col	Estimate	Std.Error	A
1	beta1	A0	R	PB	0.455257651	1.010275e+02	4.506277e-03
2	beta4	A0	DEP	NB1	0.152493606	7.505815e+01	2.031673e-03
3	beta5	A0	DEP	NB2	0.162110770	7.614170e+01	2.129067e-03
4	beta2	A0	NB1	R	0.557737131	1.034079e+02	5.393566e-03
5	beta3	A0	NB2	R	0.421398414	1.434558e+02	2.937478e-03
6	beta6	A0	DEP	R	0.412029122	9.092644e+01	4.531455e-03
7	NB1WITHNB2	S0	NB2	NB1	0.385431131	1.518898e+02	2.537570e-03
8	beta6_1	A1	DEP	R	0.001249373	5.927994e+02	2.107581e-06

meta-analíticos mediante los procedimientos estadísticos propios de esta estrategia de investigación. De todas las propiedades psicométricas, la fiabilidad ha sido la más estudiada mediante meta-análisis, denominado *Generalización de la Fiabilidad* (MA-GF). Estos estudios conllevan los objetivos propios de cualquier meta-análisis: obtener un resultado promedio (a partir de los coeficientes de fiabilidad de los estudios primarios), analizar la heterogeneidad y estudiar las fuentes de variación (Botella y Sánchez-Meca, 2015).


Este enfoque tradicional de meta-análisis tiene varios inconvenientes cuando se aplica al estudio de la fiabilidad (Scherer y Teo, 2020), tales como el reporte de diferentes índices de fiabilidad en los estudios primarios, la imposibilidad de tratar la dependencia estadística entre los coeficientes de fiabilidad de las puntuaciones totales y de las subescalas y la incapacidad de sintetizar el coeficiente de fiabilidad que mejor represente el modelo de medida del test. El coeficiente alfa, que es el más usado, se basa en supuestos que no se suelen cumplir (McNeish, 2018). Para superar estas limitaciones, se han ido desarrollando varios procedimientos que combinan técnicas meta-analíticas y SEM (Becker, 1992; Viswesvaran y Ones, 1995), hasta desembocar en los procedimientos actuales de MASEM aplicados al campo psicométrico (Jak, 2015; Scherer y Teo, 2020).

A continuación, se presenta el enfoque OSMASEM aplicándolo a un meta-análisis psicométrico realizado por Aguayo-Estremera y colaboradores (2024) sobre el Maslach Burnout Inventory (MBI; Maslach y Jackson, 1981). Este test evalúa el síndrome de burnout por medio de tres escalas que miden cansancio emocional, despersonalización y baja realización personal. Por razones de simplicidad solo se presenta el análisis con la primera escala, que consta de 9 ítems con un formato de respuesta tipo Likert de 7 puntos. En la Figura 7 puede verse el modelo de medida del ejemplo propuesto. La base de datos completa puede encontrarse en https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d.

Se empieza extrayendo, de cada estudio primario, la matriz de correlaciones inter-ítem (ver el archivo matrices.dat en el material suplementario), así como el tamaño muestral. Los estudios primarios no suelen reportar esta matriz (a menos que sean de corte psicométrico), por lo que será necesario contactar con los autores de correspondencia para conseguirlas. En nuestro ejemplo, se consiguió información de nueve estudios primarios. Una vez extraída esta información, se realizan los análisis MASEM. Como se señaló previamente, OSMASEM realiza la estimación de la matriz combinada de correlaciones

Figura 7

Modelo de medida de la escala cansancio emocional (CE) del Maslach Burnout Inventory (Maslach y Jackson, 1981)



y ajusta el modelo SEM sobre la matriz combinada en un solo paso. A diferencia del caso general, en aplicaciones psicométricas la matriz contiene las correlaciones de Pearson entre los ítems del test (no sobre las variables del modelo teórico) y el ajuste se realiza sobre el modelo de medida (en lugar de sobre el modelo teórico).

El primer paso del análisis consiste en el procesamiento de la información recabada. Las matrices de correlaciones (o, dado que son simétricas, la mitad inferior) se almacenan en un archivo .dat, que puede ser guardado como lista en R con la función `readFullMat` (o `readLowTriMat`) del paquete `metaSEM`. Los tamaños muestrales se introducen en otra lista, que luego se une a la de las matrices de correlaciones para crear el objeto que sirve para hacer los análisis posteriores. En nuestro ejemplo, las nueve matrices de correlaciones inter-ítem están en el archivo `Matrices.dat` y el objeto datos contiene en R tanto las matrices (`datos$data`) como los tamaños muestrales (`datos$n`). Un aspecto importante es comprobar que las matrices son definidas positivas mediante la función `is.pd` del mismo paquete. En caso de que haya alguna, se debe eliminar del objeto. En el ejemplo propuesto, ninguna matriz es no definida positiva, manteniéndose las nueve matrices que resultan en un total de 3493 participantes (`pattern.n(datos$data, datos$n)`). A continuación, se crea un dataframe a partir de las listas de correlaciones y de tamaños muestrales por medio de la función `Cor2data.frame`. Remitimos al lector al código que se encuentra en el repositorio para encontrar los detalles de estos análisis.

Después del procesamiento de los datos, se ajusta el modelo de medida a partir de los siguientes pasos: (a) especificar el modelo de medida en lenguaje del paquete `lavaan`; (b) crear las matrices A, S y F; (c) especificar el coeficiente de fiabilidad con la función `mxAlgebra` del paquete `OpenMX`; y (d) utilizar la función `osmasem` del paquete `metaSEM`, incluyendo el argumento `mxModel.Args` para el cálculo de la fiabilidad. En este caso, en la matriz A se especifican todas las cargas factoriales, en la matriz S se definen las varianzas (de las variables latentes) que

quedan fijadas a 1 para que el modelo se pueda estimar, y, en la matriz F se indican las variables latentes (constructos) y las observadas (ítems). Para crear estas matrices se usa la función `lavaan2RAM` del paquete `metaSEM`, especificando como argumentos el nombre del objeto que contiene el modelo de medida (`model`) y las variables observadas (`obs.variables`). En el ejemplo propuesto, se calcula el coeficiente omega total (McDonald, 1999) para la estimación de fiabilidad. Teniendo todo esto en cuenta, se ejecuta el comando siguiente para el ajuste del modelo:

```
Aj_Unifactorial <- osmasem(model.name="AFC
unifactorial congenérico con efectos aleatorios",
Mmatrix = M0, Tmatrix = T0, mxModel.Args =
list(Coef_Omega, mxCI(c("Coef_Omega"))), intervals.type =
"LB", data = BBDD).
```

Y con `summary(Aj_Unifactorial, fitIndices = T)` se imprimen los resultados (Figura 8). Con `fitIndices = T` conseguimos los índices de ajuste habituales, como RMSEA, TLI y CFI. No obstante, el índice SRMR se imprime mediante la función `osmasemSRMR`. En el ejemplo⁴, se observan valores adecuados para estos índices, por lo que se puede decir que el ajuste del modelo unidimensional congenérico a los datos es adecuado.

La columna `Estimate` nos muestra las cargas factoriales de los nueve ítems de la escala cansancio emocional (CE), que comprobamos que son altas y, por lo tanto, indican que los ítems son buenos indicadores del constructo. Para calcular el coeficiente de fiabilidad de la escala, ejecutamos `Aj_Unifactorial$Coef_Omega$result` y vemos que equivale a .879. Se podrían construir intervalos de confianza entorno a la estimación puntual con el procedimiento de Raykov y Marcoulides (2013).

Un aspecto a tener en cuenta del meta-análisis psicométrico con MASEM es que, a diferencia del tradicional, no solamente estudiamos la fiabilidad del test sino también la validez de su estructura interna (dimensionalidad). En

Por tanto, los intervalos de confianza estarían comprometidos si se basan en errores típicos.

⁴ Al ajustar el modelo con OSMASEM, aparece el aviso:
The Hessian at the solution does not appear to be convex. Information matrix is not positive definite (not at a candidate optimum). Be suspicious of these results. At minimum, do not trust the standard errors.

Figura 8

Resultados que se obtienen al ejecutar el comando `summary(Aj_Unifactorial, fitIndices = T)`

```

chi-square:  $\chi^2$  ( df=27 ) = 96.83264, p = 8.474483e-10
Information Criteria:
      | df Penalty | Parameters Penalty | Sample-Size Adjusted
AIC:   -1291.357          -643.3572          -642.1561
BIC:   -3009.583          -366.2239          -509.2106
CFI: 0.9396538
TLI: 0.9195383 (also known as NNFI)
RMSEA: 0.02721122 [95% CI (0.02032191, 0.03425997)]
Prob(RMSEA <= 0.05): 1
free parameters:
      name matrix row col Estimate Std.Error A z value Pr(>|z|)
1      L1      A0 mbi1_CE CE 0.7380518 156.514281 0.004715555 9.962375e-01
2      L2      A0 mbi2_CE CE 0.6660310 122.519065 0.005436141 9.956626e-01
3      L3      A0 mbi3_CE CE 0.7167616 150.504313 0.004762399 9.962002e-01
4      L4      A0 mbi4_CE CE 0.5552294 153.301279 0.003621818 9.971102e-01
5      L5      A0 mbi5_CE CE 0.8194777 166.826203 0.004912164 9.960807e-01
6      L6      A0 mbi6_CE CE 0.6817794 139.653652 0.004881930 9.961048e-01
7      L7      A0 mbi7_CE CE 0.5668647 105.616808 0.005367183 9.957176e-01
8      L8      A0 mbi8_CE CE 0.6370377 141.047743 0.004516468 9.963964e-01
9      L9      A0 mbi9_CE CE 0.6114135 130.794155 0.004674624 9.962702e-01

```

efecto, la síntesis meta-analítica se realiza sobre las matrices de correlaciones inter-ítem de los estudios primarios, que lleva a una matriz combinada con la que, primero, se estima y ajusta el modelo de medida (validez de estructura interna) y, segundo, a partir de las cargas factoriales, se calcula el coeficiente de fiabilidad. Esta característica deviene en dos consecuencias importantes. Por un lado, se pueden poner a prueba diferentes modelos de medida, aunque no se hayan examinado en los estudios primarios. Asimismo, se pueden comparar modelos congénricos y tau-equivalentes para elegir el índice de fiabilidad más apropiado según los requisitos del modelo de medida. Por otro lado, el estudio de la heterogeneidad, y posterior análisis de moderadores, no se realiza sobre los coeficientes de fiabilidad, sino sobre las cargas factoriales. Remitimos al lector al código del repositorio (disponible en https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d) para el estudio de la comparación de modelos y del análisis de moderadores.

Recomendaciones finales

El MASEM es una metodología avanzada de síntesis de la evidencia cuyos dos principales ámbitos de aplicación se derivan directamente de las dos metodologías que subyacen a los modelos SEM: el análisis de vías, que a nivel de MASEM permite la combinación de estudios en los que se han examinado las relaciones entre las variables que conforman un modelo teórico; y el análisis factorial, que dentro de los modelos MASEM proporciona una herramienta flexible y elegante en el campo del meta-análisis psicométrico. Un cierto grado de familiaridad con estas metodologías será de utilidad para decidir si la mejor técnica de análisis para abordar la pregunta de investigación es MASEM, en lugar de otras alternativas para la integración de múltiples resultados de cada estudio (López-López et al., 2018).

Una práctica habitual en SEM, y por extensión en MASEM, es la evaluación de índices de ajuste para comparar distintos modelos, tal y como se ha ilustrado en los

ejemplos de este tutorial. Esto puede conllevar a veces la interpretación de los resultados del modelo de efectos fijos, especialmente en aplicaciones con pocos datos, a pesar de que el modelo de efectos aleatorios suele considerarse como una opción más realista en meta-análisis (una reflexión más amplia sobre ambos modelos puede encontrarse en Borenstein et al., 2010). Además, los supuestos clásicos de estos modelos también son de aplicación aquí, incluyendo la normalidad (multivariada) de las correlaciones, para lo cual a veces se aconseja transformarlas antes de llevar a cabo los análisis (Jak, 2015); y la independencia de las observaciones, que implica que cada matriz de correlaciones haya sido obtenida a partir de muestras de participantes distintas. Si este último supuesto no se cumple, es posible adoptar estrategias similares a las empleadas en otros ámbitos del meta-análisis (Bilici et al., 2025).

En este artículo se han presentado los enfoques del MASEM basado en correlaciones y en parámetros, cada uno de los cuales tiene sus fortalezas y limitaciones (Cheung y Cheung, 2016). Los enfoques basados en correlaciones presentan un gran potencial para su aplicación en la mayoría de las situaciones debido a su capacidad para trabajar con datos perdidos, mientras que el enfoque basado en parámetros puede resultar preferible para situaciones concretas, por ejemplo, aquellas en las que sea posible ajustar el modelo teórico a nivel de cada estudio.

Actualmente, la metodología MASEM continúa desarrollándose y mejorando en diversas direcciones, como la incorporación de variables dicotómicas (e.g., correlaciones biserial-puntuales) en los análisis (de Jonge et al., 2020) y/o el uso de datos individuales (*individual participant data*) en lugar de datos agrupados (Groot et al., 2024). Aunque su aplicación todavía se limita al ámbito de la Psicología y Ciencias de la Educación, su gran versatilidad a la hora de explorar preguntas complejas de investigación a nivel meta-analítico augura una gran expansión a otros ámbitos, como la Medicina o la Ecología, consolidándose como una herramienta clave para abordar desafíos metodológicos contemporáneos.

Financiación

Proyecto financiado por la Comunidad Autónoma de la Región de Murcia a través de la convocatoria de Ayudas a proyectos para el desarrollo de investigación científica y técnica por grupos competitivos, incluida en

el Programa Regional de Fomento de la Investigación Científica y Técnica (Plan de Actuación 2022) de la Fundación Séneca-Agencia de Ciencia y Tecnología de la Región de Murcia (Proyecto N.º 22064/PI/22)

Material suplementario

Las bases de datos y los códigos de R utilizados para hacer los análisis de este manuscrito, así como el tutorial sobre cómo realizar TSSEM y OSMASEM en la aplicación webMASEM, pueden encontrarse en este enlace: https://osf.io/cq74m/?view_only=87ecffb55d87455e8a50b97e4e9b5e3d.

Referencias

- Aguayo-Estremera, R., Cañadas-De la Fuente, G. R., Ariza-Castilla, T., Ortega-Campos, E., Gómez-Urquiza, J. L., Romero-Béjar, J. L. y De la Fuente-Solana, E. I. (2024). A Comparison of Univariate and meta-Analytic Structural Equation Modelling Approaches to Reliability Generalization Applied to the Maslach Burnout Inventory. *Frontiers in Psychology*, 15, Artículo 1383619. <https://doi.org/10.3389/fpsyg.2024.1383619>
- Becker, B. J. (1992). Using Results from Replicated Studies to Estimate Linear Models. *Journal of Educational Statistics*, 17, 341–362. <https://doi.org/10.3102/10769986017004341>
- Becker, B. J. (1995). Corrections to “Using results from Replicated Studies to Estimate Linear Models”. *Journal of Educational and Behavioral Statistics*, 20, 100–102. <https://doi.org/10.3102/10769986020001100>
- Becker, B. J. y Aloe, A. M. (2019). Model-based Meta-analysis. En H. Cooper, L. V. Hedges y J. C. Valentine, *The Handbook of Research Synthesis and Meta-analysis* (3ª ed, pp. 339-363). Russell Sage.
- Bilici, Z. Ş., Van den Noortgate, W. y Jak, S. (2025). Six ways to handle dependent effect sizes in meta-analytic structural equation modeling: Is there a gold standard? *Research Synthesis Methods*, 0, 1–27. <https://doi.org/10.1017/rsm.2024.10>

- Borenstein, M., Hedges, L. V., Higgins, J. P. T. y Rothstein, H. R. (2010). A basic introduction to fixed-effect and random-effects models for meta-analysis. *Research Synthesis Methods*, 1, 97–111. <https://doi.org/10.1002/jrsm.12>
- Borenstein, M., Higgins, J. P. T., Hedges, L. V. y Rothstein, H. R. (2017). Basics of meta-analysis: I2 is not an absolute measure of heterogeneity. *Research Synthesis Methods*, 8, 5–18. <https://doi.org/10.1002/jrsm.1230>
- Botella, J. y Meca, J. S. (2015). *Metaanálisis en ciencias sociales y de la salud* [Meta-analysis in Social and Health Sciences]. Síntesis.
- Cano-López, J. B., García-Sancho, E., Fernández-Castilla, B. y Salguero, J. M. (2022). Empirical Evidence of the Metacognitive Model of Rumination and Depression in Clinical and Nonclinical Samples: A Systematic Review and Meta-Analysis. *Cognitive Therapy and Research*, 46(6), 1–26. <https://doi.org/10.1007/s10608-021-10260-2>
- Cooper, H., Hedges, L. V. y Valentine, J. C. (Eds.). (2019). *The Handbook of Research Synthesis and Meta-Analysis*. Sage.
- Cheung, M. W.-L. (2013). Multivariate Meta-Analysis as Structural Equation Models. *Structural Equation Modeling*, 20, 429–454. <https://doi.org/10.1080/10705511.2013.797827>
- Cheung, M. W.-L. (2015). *Meta-analysis: A Structural Equation Modeling Approach*. Wiley.
- Cheung, M. W.-L. (2015). metaSEM: an R Package for Meta-Analysis Using Structural Equation Modeling. *Frontiers in Psychology*, 5, Artículo 1521. <https://doi.org/10.3389/fpsyg.2014.01521>
- Cheung, M. W.-L. (2009). Constructing Approximate Confidence Intervals for Parameters with Structural Equation Models. *Structural Equation Modeling: A Multidisciplinary Journal*, 16, 267–294. <https://doi.org/10.1080/10705510902751291>
- Cheung, M. W.-L. (2019). Some Reflections on Combining Meta-Analysis and Structural Equation Modeling. *Research Synthesis Methods*, 10, 15–22. <https://doi.org/10.1002/jrsm.1321>
- Cheung, M. W.-L. y Chan, W. (2005). Meta-analytic Structural Equation Modeling: A Two-Stage Approach. *Psychological Methods*, 10, 40–64. <https://doi.org/10.1037/1082-989X.10.1.40>
- Cheung, M. W.-L. y Cheung, S. F. (2016). Random-Effects Models for Meta-Analytic Structural Equation Modeling: Review, Issues, and Illustrations. *Research Synthesis Methods*, 7, 140–155. <https://doi.org/10.1002/jrsm.1166>
- Cronbach, L. J. (1951). Coefficient Alpha and the Internal Structure Of Tests. *Psychometrika*, 16, 297–334. <https://doi.org/10.1007/BF02310555>
- De Jonge, H., Jak, S. y Kan, K. J. (2020). Dealing with Artificially Dichotomized Variables in Meta-Analytic Structural Equation Modeling. *Zeitschrift für Psychologie*, 228, 25–35. <https://doi.org/10.1027/2151-2604/a000395>
- Glass, G. V. (1976). Primary, Secondary, and Meta-Analysis of Research. *Educational Researcher*, 5, 3–8. <https://doi.org/10.3102/0013189X005010003>
- Grissom, R. J. y Kim, J. J. (2012). *Effect Sizes for Research: Univariate and Multivariate Applications* (2ª Ed.). Routledge.
- Groot, L. J., Kan, K. J. y Jak, S. (2024). Checking the Inventory: Illustrating Different Methods for Individual Participant Data Meta-Analytic Structural Equation Modeling. *Research Synthesis Methods*, 15, 872–895. <https://doi.org/10.1002/jrsm.1735>
- Hattie, J. (2008). *Visible Learning: A Synthesis of over 800 Meta-Analyses Relating to Achievement*. Routledge.

- Hedges, L. V. y Vevea, J. L. (1998). Fixed-and Random-Effects Models in Meta-Analysis. *Psychological Methods*, 3, 486–504. <https://doi.org/10.1037/1082-989X.3.4.486>
- Higgins, J. P. T. y Thompson, S. G. (2002). Quantifying Heterogeneity in a Meta-Analysis. *Statistics in Medicine*, 21, 1539–1558. <https://doi.org/10.1002/sim.1186>
- Hu, L. T. y Bentler, P. M. (1999). Cutoff Criteria for fit Indexes in Covariance Structure Analysis: Conventional Criteria versus New Alternatives. *Structural Equation Modeling: A Multidisciplinary Journal*, 6(1), 1–55. <https://doi.org/10.1080/10705519909540118>
- Jak, S. (2015). *Meta-analytic Structural Equation Modelling*. Springer <https://doi.org/10.1007/978-3-319-27174-3>
- Jak, S. y Cheung, M. W.-L. (2018a). Accounting for Missing Correlation Coefficients in Fixed-Effects MASEM. *Multivariate Behavioral Research*, 53, 1–14. <https://doi.org/10.1080/00273171.2017.1375886>
- Jak, S. y Cheung, M. W.-L. (2018b). Testing Moderator Hypotheses in Meta-Analytic Structural Equation Modeling using Subgroup Analysis. *Behavior Research Methods*, 50, 1359–1373. <https://doi.org/10.3758/s13428-018-1046-3>
- Jak, S. y Cheung, M. W.-L. (2020). Meta-analytic Structural Equation Modeling with Moderating Effects on SEM Parameters. *Psychological Methods*, 25, 430–455. <https://doi.org/10.1037/met0000245>
- Jak, S., Li, H., Kolbe, L., de Jonge, H. y Cheung, M. W.-L. (2021). Meta-analytic Structural Equation Modeling Made Easy: A Tutorial and Web Application for One-Stage MASEM. *Research Synthesis Methods*, 12, 590–606. <https://doi.org/10.1002/jrsm.1498>
- Kline, R. B. (2023). *Principles and Practice of Structural Equation Modeling* (5ª ed.). Guilford.
- Lei, P. W. y Wu, Q. (2007). Introduction to Structural Equation Modeling: Issues and Practical Considerations. *Educational Measurement: Issues and Practice*, 26, 33–43. <https://doi.org/10.1111/j.1745-3992.2007.00099.x>
- López-López, J. A., Page, M. J., Lipsey, M. W. y Higgins, J. P. T. (2018). Dealing with Effect Size Multiplicity in Systematic Reviews and Meta-Analyses. *Research Synthesis Methods*, 9, 336–351. <https://doi.org/10.1002/jrsm.1310>
- Maslach, C. y Jackson, S. E. (1981). The Measurement of Experienced Burnout. *Journal of Organizational Behavior*, 2, 99–113. <https://doi.org/10.1002/job.4030020205>
- McArdle, J. J. y McDonald, R. P. (1984). Some Algebraic Properties of the Reticular Action Model for Moment Structures. *British Journal of Mathematical and Statistical Psychology*, 37, 234–251. <https://doi.org/10.1111/j.2044-8317.1984.tb00802.x>
- McDonald, R. P. (1999). *Test Theory: A Unified Treatment*. L. Erlbaum.
- McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, 23, 412–433. <https://doi.org/10.1037/met0000144>
- Muñiz, J. (2018). *Introducción a la Psicometría. Teoría Clásica y TRI*. [Introduction to Psychometrics. Classical Theory and IRT]. Pirámide.
- Papageorgiou, C. y Wells, A. (2003). An Empirical Test of a Clinical Metacognitive Model of Rumination and Depression. *Cognitive Therapy and Research*, 27, 261–273. <https://doi.org/10.1023/A:1023962332399>
- Raykov, T. y Marcoulides, G. A. (2013). Meta-analysis of Scale Reliability Using Latent Variable

Modeling. *Structural Equation Modeling*, 20, Artículo 338353.
<https://doi.org/10.1080/10705511.2013.769396>

Rosseel, Y. (2012). lavaan: An R Package for Structural Equation Modeling. *Journal of Statistical Software*, 48(2), 1-36. <https://doi.org/10.18637/jss.v048.i02>

Ruiz, M. A., Pardo, A. y San Martín, R. (2010). Modelos de ecuaciones estructurales [Structural Equation Models]. *Papeles del Psicólogo*, 31, 34–45. <https://www.redalyc.org/pdf/778/77812441004.pdf>

Scherer, R. y Teo, T. (2020). A Tutorial on the Meta-Analytic Structural Equation Modeling of Reliability Coefficients. *Psychological Methods*, 25, 747–775. <https://doi.org/10.1037/met0000261>

Viswesvaran, C. y Ones, D. S. (1995). Theory Testing: Combining Psychometric Meta-Analysis and Structural Equations Modeling. *Personnel Psychology*, 48, 865–885. <https://doi.org/10.1111/j.1744-6570.1995.tb01784.x>.