

Organizado por



SOCIEDAD
PERUANA DE
PSICOMETRÍA

Respaldado por



UNIVERSIDAD
NACIONAL MAYOR
DE SAN MARCOS




PONENCIA

Algoritmos para optimizar escalas

Qué ítems sobreviven, cómo se agrupan, cuántos factores quedan

Dr. José Ventura-León

con OptimalFactor, un paquete de R



Llévate la presentación



No apuntes tanto, mejor apunta con tu cámara al QR.

joseventuraleon.com/diapositivas/algoritmos-optimizar-escalas

Antes de empezar: ocho tarjetas

fresa

lechuga

gorrión

cebolla

tomate

zanahoria

limón

plátano

¿Cuántos grupos ve?

dígalo en voz alta

Antes de empezar: ocho tarjetas

FRUTAS

fresa

plátano

limón

VERDURAS

zanahoria

lechuga

cebolla

¿FRUTA O VERDURA?

tomate

¿Y ESTE?

gorrión

Frutas y verduras, con sentido: pero el gorrión sobra y el tomate duda.

Antes de empezar: ocho tarjetas

LO QUE PUEDEN VER LOS DATOS: EL COLOR

COLOR OSCURO

fresa

plátano

zanahoria

gorrión

COLOR CLARO

limón

lechuga


cebolla

tomate

Nada sobra, nada duda: un buen ajuste... que no mide alimentos.

Como ítems que se agrupan por su redacción y no por su contenido.

Antes de empezar: ocho tarjetas



Los datos aceptan más de una lectura. Decide lo que usted quería medir.

Tres preguntas, tres algoritmos




¿Qué ítems sobreviven?

efa_boosting



¿Cómo se agrupan?


cfa_boosting



¿Cuántos factores quedan?

specification_search_theory

Esta ponencia trata de OptimalFactor



OptimalFactor

Un paquete de R para depurar escalas

Disponible en CRAN · versión 1.5.0

Publicado el 24 de octubre de 2026

```
install.packages("OptimalFactor")
```

Todo lo que verán hoy se hizo con este paquete.

Seis algoritmos; hoy veremos tres

En esta ponencia

1

HOY

¿Qué ítems sobreviven?

`efa_boosting`

2

HOY

¿Cómo se agrupan?

`cfa_boosting`

3

HOY

¿Cuántos factores quedan?

`specification_search_theory`

También en OptimalFactor

4

¿Los factores se distinguen entre sí?

`discriminant_boosting`

5

¿Dónde falla un modelo de un factor?

`local_fit_search`

6

¿Cómo armar una versión breve?

`redundancy_short_form`

La base de ejemplo

Teoría: F1

EA1
EA2
EA3
EA4
EA5

Teoría: F2

EA6
EA7
EA8
EA9
EA10

Data_Expectativas, incluida en OptimalFactor. Estimador WLSMV.

100

personas

10

ítems ordinales

de 3 a 5 categorías por ítem

```
# cargar la base de ejemplo  
library(OptimalFactor)  
data(Data_Expectativas)  
dim(Data_Expectativas) # 100 10
```

ALGORITMO 1 DE 3



efa_boosting()

¿Qué ítems sobreviven?




Las reglas, en orden de prioridad

Primero lo inadmisibile, después la estructura, al final el ajuste



Barandas: mínimo de ítems por factor y, si se pide, un piso de omega que veta la eliminación.

Regla 1: caso Heywood




Ejemplo didáctico: cifras ilustrativas

Regla 2: casi Heywood



Ejemplo didáctico: cifras ilustrativas

Regla 3: carga cruzada



Mide dos cosas a la vez

El ítem 4 carga en F1 (.52) y también en F2 (.41).
No se sabe a qué factor pertenece:
ensucia la frontera entre los dos.

Regla carga > .30 en dos factores → sale primero el de menor brecha: $.52 - .41 = .11$

Baranda: cada factor conserva al menos 3 ítems.


Ejemplo didáctico: cifras ilustrativas

Regla 4: ítem sin carga



Ejemplo didáctico: cifras ilustrativas


Regla 5: ajuste compuesto



Ejemplo didáctico: cifras ilustrativas

Una pérdida que se adapta a df y N

Con pocos grados de libertad, el RMSEA casi no pesa



Con pocos df y muestra pequeña, el RMSEA rechaza por error modelos que están bien.

Por eso, en esos casos, su peso baja.

Restricted access | Research article | First published online July 24, 2014 | [Re-use permissions](#)

The Performance of RMSEA in Models With Small Degrees of Freedom

David A. Kenny, Burcu Kaniskan, and D. Betsy McCoach [View all authors and affiliations](#)

Volume 44, Issue 3 | <https://doi.org/10.1177/0049124114543236>

Contents | Get access | Cite | Share options | Information, rights and permissions

Abstract

Given that the root mean square error of approximation (RMSEA) is currently one of the most popular measures of goodness-of-model fit within structural equation modeling (SEM), it is important to know how well the RMSEA performs in models with small degrees of freedom (df). Unfortunately, most previous work on the RMSEA and its confidence interval has focused on models with a large df . Building on the work of Chen et al. to examine the impact of small df on the RMSEA, we conducted a theoretical analysis and a Monte Carlo simulation using correctly specified models with varying df and sample size. The results of our investigation indicate that when the cutoff values are used to assess the fit of the properly specified models with small df and small sample size, the RMSEA too often falsely indicates a poor fitting model. We recommend not computing the RMSEA for small df models, especially those with small sample sizes, but rather estimating parameters that were not originally specified in the model.

Kenny et al. (2015), *Sociological Methods & Research*

Referencia Kenny, D. A., Kaniskan, B., & McCoach, D. B. (2015). The performance of RMSEA in models with small degrees of freedom. *Sociological Methods & Research*, 44(3), 486–507. <https://doi.org/10.1177/0049124114543236>

Qué ocurrió con la base

efa_boosting: ¿qué ítems sobreviven?



Eliminados

Ajuste del modelo de 2 factores	
10 ítems activos	
RMSEA	.088
CFI	.989
SRMR	.042

10 ítems, 2 factores teóricos: el algoritmo revisa reglas en orden de prioridad

¿Qué es una función de pérdida (loss)?

pérdida (loss)



Viene del machine learning


- 1 El modelo hace una predicción
- 2 **La pérdida resume su error en un solo número**
- 3 Aprender es cambiar el modelo para bajar ese número

Ejemplo clásico: error cuadrático $(y - \hat{y})^2$

Pérdida alta: el modelo se equivoca mucho.

¿Qué es una función de pérdida (loss)?

pérdida (loss)



Viene del machine learning


- 1 El modelo hace una predicción
- 2 La pérdida resume su error en un solo número
- 3 **Aprender es cambiar el modelo para bajar ese número**

Ejemplo clásico: error cuadrático $(y - \hat{y})^2$

Cada paso conserva el cambio que más baja la pérdida.

¿Qué es una función de pérdida (loss)?

pérdida (loss)



Viene del machine learning

- 1 El modelo hace una predicción
- 2 La pérdida resume su error en un solo número
- 3 **Aprender es cambiar el modelo para bajar ese número**

Ejemplo clásico: error cuadrático $(y - \hat{y})^2$

Pérdida 0: no queda nada que corregir y el algoritmo se detiene.

Cómo se calcula la pérdida: un ejemplo

Iteración 0 del ejemplo, ya resuelta: vamos celda por celda

Iteración 0


14 ítems · df = 64

Ejemplo didáctico: cifras ilustrativas

Índice	Valor	Meta	Exceso	$L = \text{exceso} / .03$	w (según df)	w · L
RMSEA	.101	$\leq .080$	$.101 - .080 = .021$ valor – meta	$.021 / .03 = .700$	.410	.287
SRMR	.072	$\leq .060$	$.072 - .060 = .012$ valor – meta	$.012 / .03 = .400$	.308	.123
CFI	.910	$\geq .950$	$.950 - .910 = .040$ meta – valor (más alto es mejor)	$.040 / .03 = 1.33$ más de 1 → tope: L = 1	.282	.282

$$\text{pérdida} = .287 + .123 + .282 = \mathbf{.692}$$

Los tres índices se pasan de su meta; el CFI tanto que su L llega al tope de 1.



Cómo se calcula la pérdida: un ejemplo

Iteración 1: se retira un ítem; los tres índices mejoran y la pérdida baja a .277

Iteración 1

13 ítems · df = 53


Se retira el ítem cuya salida más baja la pérdida

Ejemplo didáctico: cifras ilustrativas

Índice	Valor	Meta	Exceso	$L = \text{exceso} / .03$	w (según df)	$w \cdot L$
RMSEA	.089	$\leq .080$	$.089 - .080 = .009$ valor - meta	$.009 / .03 = .300$	.410	.123
SRMR	.064	$\leq .060$	$.064 - .060 = .004$ valor - meta	$.004 / .03 = .133$	.308	.041
CFI	.938	$\geq .950$	$.950 - .938 = .012$ meta - valor (más alto es mejor)	$.012 / .03 = .400$	.282	.113

$$\text{pérdida} = .123 + .041 + .113 = \mathbf{.277}$$

Los tres mejoran: cada L se achica y la pérdida baja.



Cómo se calcula la pérdida: un ejemplo

Iteración 2: los tres índices cumplen; pérdida 0 y efa_boosting se detiene

Iteración 2

12 ítems · df = 43


Se retira otro ítem: la pérdida vuelve a bajar

Ejemplo didáctico: cifras ilustrativas

Índice	Valor	Meta	Exceso	$L = \text{exceso} / .03$	w (según df)	w · L
RMSEA	.078	$\leq .080$	$.078 - .080 = -.002$ valor – meta · cumple $\rightarrow 0$	0	.410	0
SRMR	.055	$\leq .060$	$.055 - .060 = -.005$ valor – meta · cumple $\rightarrow 0$	0	.308	0
CFI	.953	$\geq .950$	$.950 - .953 = -.003$ meta – valor (más alto es mejor) · cumple $\rightarrow 0$	0	.282	0

$$\text{pérdida} = 0 + 0 + 0 = \mathbf{0}$$

Los tres índices cumplen: pérdida 0. efa_boosting se detiene.



¿De dónde sale el peso w?

w = peso base (df y N) × ajuste WLSMV ÷ suma así los tres pesos suman 1

Caso: **df = 64, N = 100** (el ejemplo anterior)

Paso 1. Peso base según df y N

	RMSEA	SRMR	CFI
df < 5 · N < 200	.02	.55	.43
df < 5 · N ≥ 200	.10	.48	.42
df 5-19 · N < 200	.20	.45	.35
df 5-19 · N ≥ 200	.30	.38	.32
df ≥ 20	.50	.25	.25

Con pocos df o N chica, el RMSEA pesa menos.

	RMSEA	SRMR	CFI
peso base	.50	.25	.25
Paso 2. × WLSMV	× .8	× 1.2	× 1.1
=	.400	.300	.275
<hr/>			
Paso 3. ÷ suma: .400 + .300 + .275 = .975			
	.400 / .975	.300 / .975	.275 / .975
w =	.410	.308	.282

Con muchos df el RMSEA es estable: es el índice que más pesa.

Respaldo: el tamaño del modelo cambia cómo rinde el RMSEA (Kenny y McCoach, 2003)

Kenny, D. A., & McCoach, D. B. (2003). Effect of the number of variables on measures of fit in structural equation modeling. *Structural Equation Modeling*, 10(3), 333–351. https://doi.org/10.1207/S15328007SEM1003_1

Mismo χ^2 , pocos df: el RMSEA se dispara

Los dos: $\chi^2 = 40$ y $N = 500$. Solo cambia df

$$\text{RMSEA} = \sqrt{\frac{\max(\chi^2 - df, 0)}{df(N - 1)}}$$

Modelo A · df = 20

$$\sqrt{\frac{40 - 20}{20(499)}}$$

.045


cumple: $\leq .08$

Modelo B · df = 2

$$\sqrt{\frac{40 - 2}{2(499)}}$$

.195

se rechazaría: $> .08$



Shi et al. (2022), *Multivariate Behavioral Research*

Con pocos df, el RMSEA suele rechazar modelos que están bien.

Shi, D., DiStefano, C., Maydeu-Olivares, A., & Lee, T. (2022). Evaluating SEM model fit with small degrees of freedom. *Multivariate Behavioral Research*, 57(2-3), 179–207. <https://doi.org/10.1080/00273171.2020.1868965>

Así lo cuenta la consola: efa_boosting

```
EFA OPTIMIZER v4.1 (Greedy/Global + Objetivo compuesto)
```

```
Items iniciales: 10 | Factores: 2
```

```
Targets → RMSEA ≤ 0.08 | SRMR ≤ 0.06 | CFI ≥ 0.95
```

```
Modo de búsqueda: GREEDY 1×1
```

```
Min ítems/factor: 3 | Loading umbral: 0.3
```

Parte de 10 ítems y 2 factores, con metas de ajuste y reglas declaradas

Ocho ítems sobreviven, pero se agrupan distinto a la teoría

Factor 1 empírico

EAFF6	.85
EAFF3	.73
EAFF5	.69

Factor 2 empírico

EAFF9	.96
EAFF8	.91
EAFF10	.81
EAFF4	.67
EAFF2	.66

~~EAFF7~~ ~~EAFF1~~ salen

Quedan **8** ítems en **2** factores: RMSEA = **.069**, CFI = **.995**, SRMR = **.034**. Omega: **.80** y **.90**.

Pero los colores se mezclan: los datos agrupan ítems de F1 y de F2 en un mismo factor.

Color = factor teórico:



F1



F2

ALGORITMO 2 DE 3




`cfa_boosting()`

¿Cómo se agrupan?



Partir de la teoría y corregir con evidencia


Las reglas de admisibilidad van antes que el ajuste



El MI nunca decide solo: se mira junto al EPC y la potencia (Saris et al., 2009)


Por cada par: agregar la covarianza, quitar uno, quitar el otro o quitar ambos

Paso 1: el modelo teórico



Ejemplo didáctico: cifras ilustrativas

Paso 2: piso de carga



Una flecha demasiado débil

La teoría puso a i3 en F1, pero su carga estandarizada es .22: el factor casi no lo explica (la flecha punteada).

Regla carga < .30 → sale la más baja (antes de mirar el ajuste)

Baranda: cada factor conserva al menos 3 ítems.

Ejemplo didáctico: cifras ilustrativas

Para entender la tabla de Saris

El MI es un detector de metales: ¿sonó y qué tan sensible es?

MI sig.

el detector suena

Potencia

qué tan sensible es: ¿capta un objeto de tamaño δ ?

EPC

el tamaño del objeto

δ = el objeto que importa encontrar:



.30 en cargas · .10 en errores

Saris, W. E., Satorra, A., & van der Veld, W. M. (2009). Testing structural equation models or detection of misspecifications? *Structural Equation Modeling*, 16(4), 561–582. <https://doi.org/10.1080/10705510903203433>



suena
(MI sig.)

no suena
(MI no sig.)


potencia alta
detector sensible



potencia baja
detector poco sensible




Paso 3: estructura simple




Ejemplo didáctico: cifras ilustrativas

Paso 4: pares de errores (1 de 3)



Ejemplo didáctico: cifras ilustrativas

Paso 4: la tabla de Saris (2 de 3)



Paso 4: cuatro salidas por par (3 de 3)

1

Modelo teórico

2

Piso de carga

3

Estructura simple

4


Pares de errores

5


Metas de ajuste

Para el par i1 – i2 se prueban cuatro salidas; gana la que más baja la pérdida


1. Unir los errores




2. Sacar i1



3. Sacar i2




4. Sacar los dos



1 y 3 empatan: gana la primera que se evaluó (unir los errores).


Ejemplo didáctico: cifras ilustrativas

Paso 5: metas de ajuste



Ejemplo didáctico: cifras ilustrativas

Qué ocurrió con la base



Así lo cuenta la consola: cfa_boosting

```
=====
CFA BOOSTING v1.0 - Optimización de Modelo Confirmatorio
=====
```

```
Targets -> RMSEA <= 0.08 | CFI >= 0.95 | SRMR <= 0.08
```

```
Estimador: WLSMV
```

```
Min items/factor: 3
```

```
Loading mínimo: 0.3
```

```
MI framework: Saris-Satorra-van der Veld (delta= 0.1 , power>= 0.75 , alpha= 0.05 )
```

```
Cargas cruzadas: tabla de Saris (delta = 0.3)
```


Metas de ajuste y la tabla de Saris: $\delta = .10$ para errores y $.30$ para cargas

ALGORITMO 3 DE 3



`specification_search_theory()`


¿Cuántos factores quedan?



La escalada: siempre al mejor vecino

La escalada (hill climbing)

Gana 2 factores: sin i7 y con e2 ~ e3



Color del ítem = su factor teórico · intentos: mover un ítem, quitar un ítem, poner una covarianza (ejemplo didáctico)

Una escalada por semilla

1 factor .29

2 factores .08


3 factores .17

Un cambio a la vez,
siempre el que más baja;
y desde varias semillas

Índice de congruencia: cómo se calcula

Un modelo que encontró la búsqueda (3 factores)

Color del ítem = su factor teórico (i1-i5: F1 · i6-i10: F2)



F1 tiene 5 ítems de F1 → etiqueta F1. F3 tiene 3 de F2 → etiqueta F2.

F2 (i6, i7) ya no tiene etiqueta libre: sus 2 ítems quedan fuera de su factor teórico.

Índice de congruencia (C)

$$C = 1 - \frac{\text{ítems fuera de su factor teórico}}{\text{ítems teóricos que siguen en el modelo}}$$

En el ejemplo: $C = 1 - 2 / 10 = .80$

1. Cada factor toma la etiqueta teórica más frecuente entre sus ítems (sin repetirla).
2. Se cuentan los ítems cuyo factor no lleva su etiqueta: los que cambiaron de grupo.
3. C es la proporción de ítems que se quedó en su factor teórico.

C = 1: todos siguen en su factor teórico.

C = .80: 2 de cada 10 cambiaron de grupo.

Ejemplo didáctico

Índice de congruencia: por qué y cómo se reporta

El problema

Una escalada guiada solo por el ajuste acepta cada cambio que mejora ESTA muestra: capitaliza el azar y puede no replicarse en otra (MacCallum et al., 1992).

La solución: la teoría también cuenta

$$L = L_{\text{ajuste}} + \lambda \cdot L_{\text{teoría}}$$

$L_{\text{teoría}} = .60 \cdot (1 - C) + .40 \cdot (\text{proporción de ítems quitados})$

Cada ítem que se aleja de su factor teórico encarece el cambio. $\lambda = 0$: solo ajuste; $\lambda = 1$: ajuste y teoría.

No tiene puntos de corte: es una proporción.

Se lee junto al ajuste, nunca en su lugar.

Así sale en la base ($\lambda = 1$)

Semilla	CFI	RMSEA	C	L teoría	L total
1 factor	.993	.032	.71	.29	.29
2 factores	.960	.066	1.00	.04	.04
3 factores	.959	.072	.78	.17	.17

Las tres cumplen las metas de ajuste ($L_{\text{ajuste}} = 0$):
el ajuste no las distingue; decide la congruencia.

Cómo reportarlo


"Con $\lambda = 1$, la búsqueda eligió el modelo de dos factores ($CFI = .960$, $RMSEA = .066$, $SRMR = .050$), con congruencia de 1.00 con la estructura teórica: se retiró EAF6 y se liberó EAF3 ~~ EAF5."

Reportar λ , la C del modelo elegido y de sus rivales, y validar el modelo en otra muestra.

MacCallum, R. C., Roznowski, M., & Necowitz, L. B. (1992). Model modifications in covariance structure analysis: The problem of capitalization on chance. *Psychological Bulletin*, 111(3), 490–504. <https://doi.org/10.1037/0033-2909.111.3.490>

La búsqueda completa: semillas, cambios y pérdida

1. Semillas



2. Desde cada una, un cambio a la vez



3. Gana



Se detiene cuando ningún cambio baja la pérdida. Por defecto también prueba la variante bifactor de cada semilla.

$$L = L_{\text{ajuste}} + \lambda \cdot L_{\text{teoría}}$$

L ajuste

cuánto se pasa el modelo de RMSEA .08,
CFI .95 y SRMR .08 (pesos .50, .30 y .20)

0 = cumple las tres metas

L teoría

.60 · (1 – congruencia)
+ .40 · proporción de ítems quitados

$\lambda = .50$ por defecto; $\lambda = 0$: solo ajuste

Lo que muestra la búsqueda


La teoría desempata: mismos datos, dos búsquedas

Esquema (color = factor teórico)

$\lambda = 0$ · solo ajuste

$\lambda = 1$ · ajuste + teoría

1 factor




pérdida .00 empate **gana por ir primero**

congruencia .50 · CFI .975

pérdida .29

congruencia .71 · CFI .993

2 factores




pérdida .00 empate

congruencia 1.00 · CFI .971

pérdida .04 gana

congruencia 1.00 · CFI .960

3 factores



pérdida .00 empate


congruencia .60 · CFI .952

pérdida .17


congruencia .78 · CFI .959

Pérdida = ajuste + λ · teoría. Los tres ajustan bien (ajuste = 0); lo que suma es cuánto se alejan de la teoría.

El ajuste propone; la teoría decide



El ajuste empata




La teoría decide

PARA TERMINAR

OptimalFactor


Cierre



Conclusiones: tres algoritmos, tres preguntas

1 efa_boosting

¿Qué ítems sobreviven?




Primero la estructura,
después el ajuste: un ítem
por vuelta, con reglas en orden.

Heywood · carga cruzada · piso de omega

2 cfa_boosting

¿Cómo se agrupan?




El MI nunca decide solo:
la tabla de Saris juzga cargas
cruzadas y pares de errores.

piso de carga $.30 \cdot \delta = .30$ y $.10$

3 specification_search_theory

¿Cuántos factores quedan?



Entre modelos que ajustan
igual, decide la teoría que
se declaró antes de los datos.

índice de congruencia · peso λ

El ajuste propone; la teoría decide.

Reglas explícitas, reproducibles y registradas en cada vuelta.

```
install.packages("OptimalFactor")
```

```
remotes::install_github("jventural/OptimalFactor")
```

Organizado por



SOCIEDAD
PERUANA DE
PSICOMETRÍA

Respaldado por



UNIVERSIDAD
NACIONAL MAYOR
DE SAN MARCOS



¡Gracias!

Sigamos conversando en mis redes



Facebook



LinkedIn



TikTok



YouTube



Instagram

Búscame como **Dr. José Ventura-León**

