Psicometría basada en algoritmos

Integrando Machine Learning y psicometría

Modalidad	Virtual • teórico-práctica
Duración	4 sesiones de 4 horas • 16 horas en total
Nivel	Intermedio–avanzado
Herramienta principal	OptimalFactor 1.7.0 o posterior (R), desarrollada por José Ventura-León
Público objetivo	Psicólogos, investigadores, docentes, estudiantes de posgrado y profesionales interesados en medición psicológica

1. Sumilla

El curso Psicometría basada en algoritmos: integrando Machine Learning y psicometría proporciona conocimientos teóricos y prácticos sobre la aplicación de algoritmos de optimización computacional en el análisis y refinamiento de instrumentos de medición psicológica. A partir de estrategias inspiradas en el aprendizaje automático, se abordan procedimientos de selección y depuración de ítems, optimización de estructuras factoriales exploratorias y confirmatorias, detección de errores de especificación mediante índices de modificación, cambio esperado del parámetro y potencia, búsqueda heurística de modelos, reducción de escalas y evaluación de la estabilidad de las soluciones psicométricas. Asimismo, se examinan procedimientos de simulación Monte Carlo, recuperación de estructuras teóricas, validación cruzada por mitades y comparación entre algoritmos para evaluar la consistencia y generalización de las decisiones algorítmicas. El curso utiliza la librería OptimalFactor y enfatiza una integración crítica entre el criterio teórico, la evidencia estadística y la optimización automatizada.

2. Objetivo general

Aplicar algoritmos de optimización computacional al análisis, refinamiento y evaluación de instrumentos psicométricos mediante técnicas inspiradas en Machine Learning, integrando criterios estadísticos, teóricos y de estabilidad de las soluciones.

3. Organización del contenido

SESIÓN 1 | Fundamentos de psicometría basada en algoritmos y optimización exploratoria

1. Introducción a la psicometría basada en algoritmos.
2. Relación entre Machine Learning, búsqueda heurística y análisis factorial.
3. Fundamentos de optimización psicométrica: funciones objetivo, restricciones y criterios de parada.
4. Diagnóstico previo a la optimización: distribución de las respuestas por categoría, efecto techo, categorías vacías y estimación con correlaciones policóricas y WLSMV.
5. Recuperación de la teoría antes de optimizar: análisis factoriales exploratorios con distinto número de factores contrastados con la clave teórica del instrumento.
6. Algoritmos de búsqueda greedy (eliminación ítem a ítem) y búsqueda global (eliminación de varios ítems a la vez).
7. Algoritmo EFA-Boosting para el refinamiento de estructuras factoriales exploratorias.
8. Identificación y eliminación automatizada de ítems problemáticos.
9. Optimización mediante criterios de ajuste factorial (con pesos adaptativos según los grados de libertad), cargas factoriales, casos Heywood y fiabilidad.
10. Interpretación de las trayectorias de optimización y las soluciones obtenidas.

Aplicación práctica. Diagnóstico de una base y optimización de su estructura factorial exploratoria con OptimalFactor, contrastando el número de factores que sostiene la teoría con el que sugiere el análisis paralelo.

Funciones de referencia. `efa_boosting()`, `efa_optimizer()`, `report_efa_results()`, `print_efa_results()` y `theory_recovery()` (diagnóstico inicial).

SESIÓN 2 | Algoritmos de optimización confirmatoria y búsqueda de modelos factoriales

1. Fundamentos de optimización algorítmica en el análisis factorial confirmatorio.
2. Algoritmo CFA-Boosting para el refinamiento de modelos de medición: para cada par de ítems señalado compara cuatro opciones (liberar la covarianza residual, eliminar uno u otro ítem o ambos) y aplica la de menor pérdida.
3. Detección de errores de especificación con la tabla de decisión de Saris, Satorra y van der Veld: índice de modificación, cambio esperado del parámetro (EPC) y potencia, aplicada a covarianzas residuales y a cargas cruzadas.
4. Identificación automatizada de ítems con cargas factoriales insuficientes y cargas cruzadas.
5. Búsqueda heurística de especificaciones factoriales.
6. Optimización guiada por teoría: equilibrio entre ajuste estadístico y congruencia conceptual.
7. Optimización de la validez discriminante mediante algoritmos.
8. Búsqueda de ajuste local en escalas esencialmente unidimensionales: eliminación de ítems y liberación de covarianzas residuales.
9. Evaluación de estructuras bifactor mediante índices psicométricos especializados (ECV, PUC, ωH y H) y detección de bifactores espurios, que mejoran el ajuste sin describir un constructo.
10. ¿Tiene sentido un puntaje total? Evidencia desde Schmid-Leiman, el modelo bifactor y el bifactor S·I−1.

Aplicación práctica. Comparación de modelos confirmatorios originales y optimizados mediante búsqueda algorítmica, considerando ajuste, interpretabilidad y congruencia teórica. Incluye la lectura paso a paso de la trayectoria de `cfa_boosting()` y un caso real en que la búsqueda de especificación solo alcanzó el ajuste con un bifactor espurio.

Funciones de referencia. `cfa_boosting()`, `report_cfa_results()`, `specification_search_theory()`, `discriminant_boosting()`, `local_fit_search()` (modelos de un factor) y `bifactor_indices()`.

SESIÓN 3 | Selección automatizada de ítems y optimización de instrumentos psicométricos

1. Fundamentos de selección algorítmica de ítems.
2. Estrategias de reducción automatizada de escalas psicológicas.
3. Identificación de redundancia (dependencia local) entre ítems mediante correlaciones residuales.
4. Optimización de versiones breves de escalas esencialmente unidimensionales.
5. Restricciones de fiabilidad durante el proceso de selección (umbral de omega y pisos adaptativos de carga y fiabilidad).
6. Integración de inteligencia artificial para el análisis conceptual de los ítems eliminados y la denominación de los factores (requiere una clave de API de un modelo de lenguaje).
7. Equilibrio entre parsimonia, fiabilidad y cobertura del constructo.
8. Equivalencia entre la versión breve y la completa: correlación entre sus puntajes.
9. Optimización conjunta de dimensionalidad y selección de ítems (tema previsto); aproximación disponible mediante la búsqueda de especificación de 1 a k factores.

Aplicación práctica. Construcción y evaluación de una versión abreviada de un instrumento psicológico mediante procedimientos automatizados, y comparación de sus puntajes con los de la versión completa.

Funciones de referencia. `redundancy_short_form()`, `efa_boosting(use_ai_analysis = TRUE)`, `optimal_efa_with_ai()`, `optimal_cfa_with_ai()`, `print_conceptual_analysis()` y `export_conceptual_analysis()`.

Tema previsto. Optimización simultánea del número de factores y la selección de ítems; demostración temática condicionada a que el procedimiento esté implementado antes del curso. Mientras tanto, se muestra la aproximación disponible: `specification_search_theory()` explora modelos de 1 a `max_factors` factores combinando mover ítems, eliminarlos y liberar covarianzas residuales.

SESIÓN 4 | Estabilidad algorítmica, simulación y validación de modelos psicométricos

1. Fundamentos de estabilidad y reproducibilidad de las decisiones algorítmicas.
2. Evaluación de la estabilidad de la selección y de la asignación de ítems mediante remuestreo, en el marco exploratorio y en el confirmatorio.
3. Recuperación de estructuras factoriales teóricas.
4. Comparación de soluciones psicométricas mediante indicadores de congruencia y recuperación (retención, exactitud, índice de Rand ajustado y congruencia de Tucker).
5. Validación cruzada por mitades: derivar la estructura en una mitad de la muestra y ajustarla como AFC en la otra.
6. Simulaciones Monte Carlo para evaluar el desempeño de algoritmos.
7. Sensibilidad, especificidad y recuperación de estructuras factoriales.
8. Competencia de algoritmos: elegir entre soluciones con criterios comunes (ajuste, validez discriminante, fiabilidad, recuperación de la teoría y estabilidad) sobre las mismas particiones.
9. Análisis de sensibilidad: fusión de categorías con pocas respuestas y efecto del tamaño de la muestra de validación sobre los índices de ajuste.
10. Capitalización del azar, sobreajuste y limitaciones de la optimización automatizada; carácter exploratorio de toda depuración basada en los datos.

Aplicación práctica. Competencia de algoritmos sobre una misma escala: aplicar varios algoritmos desde los mismos ítems, reajustar cada solución final como AFC, evaluar su estabilidad por mitades y su recuperación de la teoría, y elegir y justificar la solución. Se complementa con simulaciones para determinar la consistencia de las decisiones algorítmicas.

Funciones de referencia. `item_stability()`, `cfa_item_stability()`, `algorithm_stability()`, `theory_recovery()`, `cross_validate_cfa()` (escalas de un factor), `simulate_recovery()` y `simulate_cfa_recovery()`.

4. Metodología

El curso se desarrolla mediante una metodología teórico-práctica, con explicaciones conceptuales, demostraciones computacionales y ejercicios de aplicación utilizando datos psicométricos. Las actividades priorizan la comprensión de los algoritmos, la interpretación de resultados y la evaluación crítica de las decisiones automatizadas. Se empleará OptimalFactor mediante ejemplos guiados en R y, cuando corresponda, su interfaz web independiente. Las prácticas usan las bases incluidas en la librería (`Data_Expectativas` y `Data_Personality`) y casos reales de validación. En los procedimientos de cómputo prolongado, como la búsqueda de especificación o la estabilidad por remuestreo, se trabajará con resultados precalculados para dedicar la sesión a su interpretación.

Se requiere OptimalFactor 1.7.0 o posterior. Si esa versión aún no estuviera en CRAN, se instalará desde GitHub con remotes::install_github("jventural/OptimalFactor"). La demostración de los procedimientos con inteligencia artificial la realiza el docente, ya que requieren una clave de API de pago.

Énfasis formativo: aplicar e interpretar algoritmos psicométricos, no programar algoritmos nuevos desde cero.

5. Resultados de aprendizaje

- Comprender los fundamentos de la optimización computacional aplicada a la psicometría.
- Aplicar algoritmos de refinamiento de estructuras factoriales exploratorias y confirmatorias.
- Utilizar estrategias automatizadas para seleccionar ítems y obtener versiones abreviadas de instrumentos.
- Elegir y justificar el algoritmo adecuado según el problema de la escala (dimensionalidad, validez discriminante o dependencia local).
- Evaluar la estabilidad, congruencia teórica y recuperación de soluciones psicométricas.

- Interpretar críticamente los resultados de procedimientos algorítmicos, reconociendo sus ventajas y limitaciones.
- Reconocer soluciones con buen ajuste y mala medición, como los modelos bifactor espurios, y declarar el carácter exploratorio de la depuración.

6. Nota sobre la incorporación de un nuevo algoritmo

Tema previsto: optimización conjunta del número de factores y la selección de ítems.

Se propone incorporar este procedimiento a la tercera sesión una vez que haya sido desarrollado e integrado a OptimalFactor. El enfoque busca superar una limitación de los procedimientos que requieren establecer de antemano el número de factores. Su propósito sería evaluar simultáneamente alternativas de dimensionalidad y selección de ítems considerando criterios de ajuste, parsimonia, fiabilidad y estabilidad.

Su incorporación al curso sería exclusivamente temática y aplicada: explicación de fundamentos y, si ya estuviera implementado, demostración de funcionamiento. No se contempla programarlo o desarrollarlo durante la sesión. Si aún no estuviera disponible, se abordaría conceptualmente como línea futura de investigación y se mostraría la aproximación actual con `specification_search_theory()`, que ya explora distintos números de factores mientras elimina o reasigna ítems.

7. Eje pedagógico de las sesiones

Sesión	Pregunta orientadora
1. Exploración	¿Cómo pueden los algoritmos optimizar una estructura factorial exploratoria?
2. Confirmación	¿Cómo refinar modelos confirmatorios sin perder coherencia teórica?
3. Selección de ítems	¿Cómo seleccionar ítems y optimizar la estructura de un instrumento?
4. Validación	¿Cómo saber si una solución algorítmica es estable, recuperable y generalizable?

Principio transversal: una solución con mejores índices de ajuste no necesariamente representa una mejor medición del constructo.

8. Guía para elegir el algoritmo

El algoritmo de partida depende del problema que presenta la escala. La elección final no descansa en un solo índice: se exige ajuste, factores que se distingan, puntajes fiables, conservación de la teoría y réplica en una muestra que no participó en la derivación.

Situación de la escala	Algoritmo de partida
Estructura exploratoria por depurar	`efa_boosting()`
Modelo teórico que no ajusta por ítems o pares de ítems concretos	`cfa_boosting()`
Factores que no se distinguen (correlación ≥ .90)	`discriminant_boosting()`
Escala unidimensional que no ajusta por ítems redundantes	`local_fit_search()` o `redundancy_short_form()`
Duda sobre el número de factores o la asignación de ítems	`specification_search_theory()`
Elegir entre las soluciones de varios algoritmos	`theory_recovery()` y `algorithm_stability()`

Nota: las funciones `local_fit_search()`, `redundancy_short_form()` y `cross_validate_cfa()` suponen una escala esencialmente unidimensional.

9. Recursos de referencia

Repositorio: https://github.com/jventural/OptimalFactor

Documentación: https://jventural.github.io/OptimalFactor/

Nota: el contenido y los ejemplos prácticos podrán ajustarse a las funciones efectivamente disponibles en la versión de OptimalFactor utilizada al impartir el curso.

10. Referencias básicas

Eid, M., Geiser, C., Koch, T., & Heene, M. (2017). Anomalous results in G-factor models: Explanations and alternatives. *Psychological Methods, 22*(3), 541–562. https://doi.org/10.1037/met0000083

Hubert, L., & Arabie, P. (1985). Comparing partitions. *Journal of Classification, 2*(1), 193–218. https://doi.org/10.1007/BF01908075

Lorenzo-Seva, U., & ten Berge, J. M. F. (2006). Tucker's congruence coefficient as a meaningful index of factor similarity. *Methodology, 2*(2), 57–64. https://doi.org/10.1027/1614-2241.2.2.57

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

Rodriguez, A., Reise, S. P., & Haviland, M. G. (2016). Evaluating bifactor models: Calculating and interpreting statistical indices. *Psychological Methods, 21*(2), 137–150. https://doi.org/10.1037/met0000045

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