

PERFILES DE ESTUDIANTES DE EDUCACIÓN SECUNDARIA EN RELACIÓN CON LAS MATEMÁTICAS Y EL USO DE INTELIGENCIA ARTIFICIAL

Secondary education student profiles in relation to mathematics and the use of artificial intelligence

Mohamed-Chemlali, N.^a, Hossein-Mohand, H.^b y Hossein-Mohand, H.^b

^aUniversidad Nacional de Educación a Distancia (UNED), ^bUniversidad de Granada

Resumen

Este estudio analiza la relación entre el uso de herramientas de inteligencia artificial, la relación del alumnado con las matemáticas y sus estrategias de estudio en estudiantes de educación secundaria de la ciudad de Melilla. Se realizó un estudio cuantitativo transversal con 689 estudiantes mediante cuestionario digital y análisis multivariante. El análisis factorial identificó tres dimensiones (uso de inteligencia artificial, relación con las matemáticas y estrategias de estudio) y el análisis de conglomerados permitió identificar tres perfiles de estudiantes. Los resultados muestran que el perfil con una relación más positiva con las matemáticas y mayor dedicación al estudio presenta el mayor rendimiento académico, mientras que el uso de inteligencia artificial por sí solo no se asocia necesariamente con mejores resultados.

Palabras clave: educación matemática, inteligencia artificial, estrategias de estudio, rendimiento académico, educación secundaria

Abstract

This study examines the relationship between the use of artificial intelligence tools, students' attitudes towards mathematics and their study strategies in secondary education students from Melilla (Spain). A quantitative cross-sectional study was conducted with 689 students using a digital questionnaire and multivariate analyses. Exploratory factor analysis identified three dimensions (AI use, relationship with mathematics and study strategies), and cluster analysis revealed three student profiles. Results show that students with a more positive relationship with mathematics and greater study dedication achieve higher academic performance, while AI use alone is not necessarily associated with better results.

Keywords: mathematics education, artificial intelligence, study strategies, academic achievement, secondary education

INTRODUCCIÓN

El aprendizaje de las matemáticas en educación secundaria constituye una prioridad en las políticas educativas actuales, donde se promueve el desarrollo de competencias orientadas a interpretar, modelizar y resolver problemas en distintos contextos (Niss y Højgaard, 2019). En este marco, el currículo incorpora de forma creciente herramientas digitales como apoyo al aprendizaje, entre ellas tecnologías basadas en inteligencia artificial (IA) capaces de generar explicaciones, resolver ejercicios o apoyar el estudio de contenidos matemáticos (Van Vaerenbergh y Pérez-Suay, 2021; Kasneci et al., 2023; Bond et al., 2024).

En este estudio, la referencia a las matemáticas se concreta en la matemática escolar de educación secundaria, entendida como el conjunto de contenidos y prácticas propios de la asignatura en esta

etapa. En particular, el análisis considera la relación del alumnado con contenidos como álgebra, funciones, números, estadística y probabilidad, así como con prácticas habituales de estudio matemático, entre ellas la resolución de ejercicios, el repaso de contenidos, el uso de apuntes, el empleo de videotutoriales y la preparación de pruebas. De este modo, el uso de herramientas de IA no se analiza como una práctica tecnológica general, sino como un recurso potencialmente vinculado al estudio y aprendizaje de contenidos matemáticos escolares.

La incorporación de estas herramientas plantea nuevos retos para la investigación en educación matemática, especialmente en relación con la forma en que el alumnado integra estos recursos en sus hábitos de estudio y cómo su uso se relaciona con variables tradicionalmente asociadas al aprendizaje de las matemáticas, como la motivación, el interés por la asignatura, el autoconcepto o la dedicación al estudio (García-Alonso et al., 2021; Hossein-Mohand y Hossein-Mohand, 2023; Schukajlow et al., 2023). Analizar conjuntamente estas dimensiones permite identificar posibles perfiles de estudiantes y examinar su relación con el rendimiento académico, una aproximación que ha sido utilizada en investigaciones recientes para comprender distintos patrones de implicación académica del alumnado en matemáticas (Tuominen-Soini et al., 2020; Widlund et al., 2024).

El presente estudio analiza estas variables en una muestra de estudiantes de educación secundaria de distintos centros educativos de la ciudad de Melilla, un contexto caracterizado por una elevada heterogeneidad sociocultural del alumnado. Teóricamente, el trabajo se sitúa en la intersección de tres ejes teóricos relevantes para la educación matemática: la relación afectivo-motivacional del alumnado con las matemáticas, las estrategias de estudio vinculadas al aprendizaje autorregulado y el uso de herramientas de IA como apoyo al estudio matemático. Desde esta perspectiva, el rendimiento en matemáticas no se interpreta únicamente como resultado de la exposición a recursos tecnológicos, sino como consecuencia de la articulación entre actitudes hacia la asignatura, hábitos de estudio y formas de uso de dichos recursos.

En primer lugar, la relación del alumnado con las matemáticas constituye una dimensión ampliamente estudiada en educación matemática. Variables como el interés por la asignatura, la motivación, las emociones académicas y la disposición hacia la resolución de tareas matemáticas influyen en la implicación del alumnado y en su persistencia ante la dificultad. La investigación reciente ha señalado que los procesos afectivos y motivacionales son componentes esenciales para comprender el aprendizaje matemático, ya que condicionan la participación del alumnado y la forma en que afronta los contenidos y problemas de la asignatura (Schukajlow et al., 2023; Widlund et al., 2024).

En segundo lugar, las estrategias de estudio se vinculan con la forma en que el alumnado organiza, regula y sostiene su aprendizaje. El tiempo dedicado al estudio, la frecuencia de repaso, el uso de apuntes, libros de texto o videotutoriales no constituyen simples hábitos aislados, sino indicadores de una determinada forma de implicación académica. Desde el enfoque del aprendizaje autorregulado, estas prácticas permiten interpretar cómo el alumnado planifica, supervisa y ajusta su proceso de aprendizaje, especialmente en una asignatura como matemáticas, donde la comprensión conceptual y la práctica razonada resultan fundamentales (Kim et al., 2020; Widlund et al., 2024).

En tercer lugar, las herramientas de IA introducen nuevas posibilidades y desafíos en el aprendizaje de las matemáticas. Estas tecnologías pueden proporcionar explicaciones, resolver ejercicios, ofrecer ejemplos y apoyar el estudio autónomo; sin embargo, su valor educativo depende del modo en que son utilizadas por el alumnado. Un uso frecuente de IA no implica necesariamente una mejora del aprendizaje si no se integra en estrategias orientadas a la comprensión, la reflexión y la resolución razonada de problemas matemáticos (Bond et al., 2024; Kasneci et al., 2023; Zawacki-Richter et al., 2019). Por ello, en este estudio el uso de IA se analiza como una dimensión del perfil de aprendizaje del alumnado, y no como una variable tecnológica aislada.

Desde este marco, la identificación de perfiles de estudiantes permite analizar cómo se combinan estas tres dimensiones en la experiencia escolar. Esta aproximación resulta pertinente porque permite

superar análisis centrados en variables independientes y observar configuraciones más amplias de aprendizaje. En consecuencia, el objetivo general es analizar la relación entre el uso de herramientas de IA en el estudio de contenidos matemáticos escolares, la relación del alumnado con las matemáticas y las estrategias de estudio, con el fin de identificar perfiles de estudiantes y examinar su relación con el rendimiento académico en matemáticas. De forma específica, se pretende: a) identificar las dimensiones latentes asociadas al uso de IA para el estudio de las matemáticas; b) determinar perfiles de estudiantes a partir de dichas dimensiones; c) analizar las diferencias en el rendimiento académico en matemáticas entre los perfiles identificados; y d) examinar la posible relación entre la pertenencia a dichos perfiles y variables sociodemográficas como el género y el nivel educativo.

En relación con estos objetivos se plantean las siguientes hipótesis de investigación: H1) las variables relacionadas con el aprendizaje de las matemáticas se organizan en dimensiones diferenciadas asociadas al uso de IA, la relación con las matemáticas y las estrategias de estudio; H2) existen perfiles diferenciados de estudiantes en función de su uso de IA, su relación con las matemáticas y sus estrategias de estudio; H3) los perfiles presentan diferencias estadísticamente significativas en el rendimiento académico en matemáticas; y H4) la pertenencia a los perfiles no depende significativamente del género ni del nivel educativo del alumnado.

METODOLOGÍA

Diseño de investigación

Se realizó un estudio cuantitativo, no experimental y transversal mediante un diseño ex post facto. Para identificar perfiles se aplicaron técnicas de análisis multivariante, incluyendo un análisis factorial exploratorio y un análisis de conglomerados. Posteriormente se analizaron las diferencias entre los perfiles en el rendimiento académico en matemáticas y en variables sociodemográficas.

Participantes

La muestra estuvo formada por 689 estudiantes de Educación Secundaria Obligatoria y educación postobligatoria de distintos centros educativos de la ciudad de Melilla (España), seleccionados mediante muestreo incidental. Para los análisis multivariantes se utilizaron 499 casos válidos tras excluir los cuestionarios con valores perdidos. La participación fue voluntaria y anónima.

Instrumento

La recogida de datos se realizó mediante un cuestionario digital administrado a través de *Google Forms*. El cuestionario original incluía 174 ítems organizados en nueve dimensiones y formulados mayoritariamente mediante una escala Likert de cinco puntos, además de preguntas sociodemográficas. Para el presente estudio se seleccionaron 26 ítems relacionados con tres ámbitos del aprendizaje de las matemáticas: el uso de IA como apoyo al estudio de la asignatura, la relación afectivo-motivacional del alumnado con las matemáticas y las estrategias de estudio empleadas para preparar y comprender los contenidos matemáticos. El bloque de uso y actitud hacia la IA en matemáticas incluyó los ítems AIA (IA ayuda a realizar ejercicios), CUS (frecuencia semanal de uso de IA), ILJ (horas de uso de IA entre semana), IAF (horas de uso de IA en fin de semana), UHI (uso de IA mientras se estudia), CHE (uso de IA para aprender o repasar), MTI (motivación para estudiar con IA), TIA (interés por herramientas de IA), AMI (preferencia por aprender con IA) y CIA (dificultad para usar IA). El bloque de relación con las matemáticas incluyó TGM (gusto por las matemáticas), MGA (motivación por la asignatura), GBA (interés por álgebra), GBF (interés por funciones), GBN (interés por números), GBE (interés por estadística y probabilidad), TCM (dificultad para aprobar matemáticas), MPM (motivación del profesorado) y MEF (motivación por el futuro). El bloque de estrategias de estudio incluyó LJM (horas de estudio entre semana), VSM (horas de estudio en fin de semana), DSE (días de estudio de matemáticas), ULT (uso del libro de texto), UAE (uso de apuntes de clase), UVI (uso de videotutoriales) y UAI (uso de apuntes de internet). La

consistencia interna se analizó por bloques de contenido, obteniéndose valores adecuados para relación con las matemáticas ($\alpha = .820$) y uso y actitud hacia la IA en matemáticas ($\alpha = .767$), y un valor aceptable, aunque más moderado para estrategias de estudio ($\alpha = .638$). Como variables de rendimiento académico en matemáticas se consideraron la nota media en la asignatura (NMP), la nota del primer trimestre (NPT) y la nota del segundo trimestre (NST).

Procedimiento de recogida de datos

El cuestionario fue revisado y autorizado por la Unidad de Programas Educativos de la Dirección Provincial del Ministerio de Educación y Formación Profesional en Melilla. Tras contactar con los centros participantes, la recogida de datos se realizó durante el año 2024 mediante un cuestionario digital administrado en aulas de informática a través de *Google Forms*, previa obtención del consentimiento informado de las familias. La participación fue voluntaria y anónima y durante la aplicación del cuestionario se contó con la supervisión del profesorado o del equipo investigador. El estudio fue aprobado por el Comité de Ética de la Universidad Nacional de Educación a Distancia (UNED) (Ref. 31-SISH-EDU-2024).

Técnicas de análisis de datos

El análisis estadístico se realizó con IBM SPSS Statistics. En primer lugar, se llevaron a cabo análisis descriptivos de las variables sociodemográficas y de los principales ítems del cuestionario. Los ítems inversos TCM y CIA fueron recodificados antes de los análisis. Asimismo, se estimó la consistencia interna de los bloques de ítems mediante el alfa de Cronbach. Posteriormente se realizó un análisis factorial exploratorio, técnica adecuada para identificar la estructura latente de un conjunto de variables observadas y reducirlas a dimensiones interpretables (Hair et al., 2019; Tabachnick y Fidell, 2019). Se utilizó factorización de eje principal con rotación oblicua Oblimin, dado que se esperaba relación entre las dimensiones vinculadas al aprendizaje matemático. La adecuación de los datos se comprobó mediante los índices KMO y la prueba de esfericidad de Bartlett. A partir de las puntuaciones factoriales se identificaron perfiles de estudiantes mediante análisis de conglomerados jerárquico (método de Ward), para explorar la solución de grupos y posteriormente k-means, para optimizar la asignación de los casos. Las diferencias entre clústeres en el rendimiento académico se analizaron mediante ANOVA con comparaciones post hoc de Tukey, y la relación entre clústeres y variables sociodemográficas mediante pruebas χ^2 de Pearson.

RESULTADOS

Estructura factorial de las variables analizadas: contraste de H1

Con el objetivo de analizar la estructura de las variables relacionadas con el aprendizaje de las matemáticas, el uso de herramientas de IA y los hábitos de estudio del alumnado, se realizó un análisis factorial exploratorio sobre los ítems seleccionados.

Tabla 7

Resultados del análisis factorial exploratorio

Factor	Variable	Carga factorial
Factor 1 – Uso y actitud hacia la IA	AIA	0,730
	CUS	0,699
	ILJ	0,696
	IAF	0,682
	UHI	0,636
	CHE	0,615
	MTI	0,607

Factor	Variable	Carga factorial
Factor 2 – Relación con las matemáticas	TIA	0,397
	UAI	0,330
	AMI	0,326
	TGM	0,855
	MGA	0,775
	GBA	0,652
	GBF	0,643
	GBN	0,542
	GBE	0,467
	TCM (recodificada)	0,459
Factor 3 – Estrategias de estudio	MPM	0,353
	LJM	0,774
	VSM	0,645
	DSE	0,634

Nota. Método de extracción: factorización de eje principal. Método de rotación: Oblimin con normalización Kaiser. KMO = 0,813. Prueba de esfericidad de Bartlett: $\chi^2(325) = 3999,60$, $p < 0,001$. Los tres factores explican 34,47% de la varianza total.

Los resultados del análisis factorial exploratorio se presentan en la Tabla 1. Los indicadores de adecuación muestral confirmaron la pertinencia del análisis (KMO = 0,813; prueba de esfericidad de Bartlett $\chi^2(325) = 3999,60$, $p < 0,001$). Los tres factores extraídos explican el 34,47% de la varianza total y permiten diferenciar tres dimensiones vinculadas al aprendizaje matemático: uso y actitud hacia la IA, relación con las matemáticas y estrategias de estudio. El primer factor agrupa variables relacionadas con la utilización de IA como apoyo al estudio; el segundo integra variables afectivo-motivacionales asociadas a la asignatura; y el tercero reúne indicadores de tiempo y frecuencia de estudio. Estos resultados respaldan la H1, al mostrar que las variables analizadas se organizan en tres dimensiones diferenciadas.

Identificación de perfiles de estudiantes: contraste de H2

A partir de las puntuaciones factoriales obtenidas, se realizó un análisis de conglomerados para determinar si existían perfiles de estudiantes en función de las tres dimensiones identificadas.

Tabla 2

Centros de los clústeres obtenidos a partir de las puntuaciones factoriales

Factor	Clúster 1	Clúster 2	Clúster 3
Factor 1 (uso y actitud hacia la IA)	1,153	-0,447	-0,513
Factor 2 (relación con las matemáticas)	-0,305	-0,544	0,734
Factor 3 (estrategias y dedicación al estudio)	0,116	-0,654	0,498

Nota. Puntuaciones factoriales estandarizadas obtenidas mediante k-means. Tamaño de los clústeres: C1 = 147, C2 = 167, C3 = 185; N = 499.

La Tabla 2 presenta los centros de los clústeres obtenidos a partir de las puntuaciones factoriales. El análisis mediante k-means permitió identificar tres grupos de estudiantes con tamaños relativamente equilibrados. El clúster 1 se caracteriza por un mayor uso y actitud más favorable hacia la IA; el clúster 2 presenta puntuaciones bajas en las tres dimensiones analizadas; y el clúster 3 muestra una

relación más positiva con las matemáticas y mayores estrategias de estudio. Estos resultados respaldan la H2 al evidenciar la existencia de perfiles diferenciados de estudiantes.

Diferencias en el rendimiento académico entre perfiles: contraste de H3

Para analizar si los perfiles identificados diferían en el rendimiento académico en matemáticas, se compararon las medias de nota media en matemáticas, nota del primer trimestre y nota del segundo trimestre mediante ANOVA.

Tabla 3

Rendimiento matemático según clúster

Clúster	NMP Media (DT)	NPT Media (DT)	NST Media (DT)
1	3,10 (1,16)	2,56 (1,27)	2,72 (1,29)
2	2,95 (1,23)	2,34 (1,27)	2,49 (1,32)
3	3,58 (1,25)	3,23 (1,34)	3,34 (1,34)

Nota. NMP = nota media en matemáticas; NPT = nota del primer trimestre; NST = nota del segundo trimestre. Resultados del ANOVA: NMP ($F = 12,89, p < 0,001$), NPT ($F = 22,28, p < 0,001$) y NST ($F = 19,61, p < 0,001$).

La Tabla 3 muestra diferencias significativas entre los clústeres en las tres medidas de rendimiento académico consideradas: nota media en matemáticas, nota del primer trimestre y nota del segundo trimestre. El clúster 3 obtuvo las medias más elevadas en todas las variables, mientras que el clúster 2 presentó las puntuaciones más bajas y el clúster 1 valores intermedios. Las comparaciones post hoc mediante Tukey indicaron que el clúster 3 presenta medias significativamente superiores a las de los otros dos grupos, sin diferencias significativas entre los clústeres 1 y 2. Estos resultados respaldan la H3, ya que los perfiles identificados presentan diferencias significativas en el rendimiento académico, especialmente a favor del clúster 3.

Relación entre perfiles y variables sociodemográficas: contraste de H4

Finalmente, se examinó si la pertenencia a los perfiles identificados se asociaba con el género o el nivel educativo del alumnado.

Tabla 4

Relación entre los perfiles de estudiantes y variables demográficas

Variable	χ^2	gl	p
Género	2,70	4	0,608
Curso	12,31	8	0,138

Nota. Prueba χ^2 de Pearson. $N = 499$.

La Tabla 4 muestra que no existen asociaciones estadísticamente significativas entre la pertenencia a los perfiles identificados y el género ni el curso. Estos resultados respaldan la H4 y sugieren que la distribución del alumnado en los perfiles se relaciona principalmente con las dimensiones de aprendizaje analizadas, y no con las variables sociodemográficas consideradas.

DISCUSIÓN

El presente estudio analizó la relación entre el uso de herramientas de IA en el estudio de contenidos matemáticos escolares, la relación del alumnado con las matemáticas y las estrategias de estudio, con el objetivo de identificar perfiles de estudiantes y examinar su relación con el rendimiento académico en matemáticas. La discusión se organiza de acuerdo con las cuatro hipótesis planteadas, con el fin

de mantener la conexión entre los objetivos, los análisis realizados y la interpretación de los resultados.

En relación con la hipótesis H1, los resultados del análisis factorial exploratorio confirmaron la existencia de tres dimensiones diferenciadas en el aprendizaje de las matemáticas: uso de IA, relación con la asignatura y estrategias de estudio. Este resultado respalda la hipótesis planteada y coincide con investigaciones previas que señalan que el aprendizaje matemático está condicionado por la interacción de variables motivacionales, actitudinales y comportamentales (Schukajlow et al., 2023; Widlund et al., 2024).

Asimismo, la identificación de una dimensión específica vinculada al uso de IA refleja la creciente presencia de estas herramientas en los procesos de aprendizaje. La literatura reciente ha señalado que los sistemas basados en IA están transformando los entornos educativos al facilitar el acceso a explicaciones y recursos de aprendizaje autónomo (Kasneci et al., 2023; Bond et al., 2024). No obstante, diversos estudios advierten que su impacto educativo depende en gran medida de la forma en que el alumnado integra estas herramientas en sus estrategias de estudio y en los procesos de aprendizaje autorregulado (Zawacki-Richter et al., 2019).

En relación con la hipótesis H2, el análisis de conglomerados permitió identificar tres perfiles de estudiantes. El primero se caracteriza por un mayor uso de IA en el estudio de las matemáticas; el segundo presenta puntuaciones bajas en las tres dimensiones analizadas; y el tercero se distingue por una relación más positiva con la asignatura y mayores niveles de dedicación al estudio. Estos resultados son coherentes con investigaciones que utilizan enfoques basados en perfiles motivacionales para analizar la implicación académica del alumnado en matemáticas y su relación con diferentes patrones de aprendizaje (Lazarides et al., 2021; Widlund et al., 2024).

Respecto a la hipótesis H3, los resultados del análisis de varianza mostraron diferencias significativas en el rendimiento académico entre los perfiles identificados. El clúster 3, caracterizado por una relación más positiva con las matemáticas y mayores estrategias de estudio, obtuvo las medias más altas en las tres medidas de rendimiento: nota media en matemáticas y calificaciones del primer y segundo trimestre. En cambio, el clúster 1, definido por un mayor uso y una actitud más favorable hacia la IA, presentó resultados intermedios. Este hallazgo permite matizar una interpretación tecnocéntrica del aprendizaje matemático: la frecuencia de uso de IA no parece suficiente para configurar el perfil de mayor rendimiento si no se acompaña de una relación positiva con la asignatura y de prácticas de estudio sostenidas (Kasneci et al., 2023; Bond et al., 2024).

Finalmente, en relación con la hipótesis H4, los resultados mostraron que la pertenencia a los perfiles identificados no se asocia de forma significativa con variables sociodemográficas como el género o el nivel educativo. Este resultado sugiere que los perfiles observados están más vinculados con la experiencia de aprendizaje del alumnado que con características demográficas, algo que también ha sido señalado en investigaciones recientes sobre perfiles motivacionales y participación académica en matemáticas (Lazarides et al., 2021; Widlund et al., 2024).

CONCLUSIONES

Los resultados de este estudio muestran que los perfiles de estudiantes no se diferencian únicamente por su nivel de rendimiento, sino por la forma en que se combinan tres dimensiones del aprendizaje matemático: el uso de herramientas de IA, la relación con las matemáticas y las estrategias de estudio. La principal aportación del trabajo es que el perfil con mayor uso y actitud más favorable hacia la IA no es el perfil que alcanza mejores resultados académicos. El mayor rendimiento se observa en el grupo caracterizado por una relación más positiva con las matemáticas y por estrategias de estudio más consistentes, aunque este grupo no presenta el mayor uso de IA.

Desde una perspectiva educativa, estos resultados subrayan la importancia de promover no solo el acceso a recursos tecnológicos, sino también el desarrollo de actitudes positivas hacia las matemáticas

y estrategias de estudio eficaces. La integración de herramientas de IA en el aprendizaje matemático debería orientarse a apoyar la comprensión, la práctica razonada y la autorregulación, evitando reducir la innovación educativa a la mera frecuencia de uso tecnológico. Entre las limitaciones del estudio destacan su carácter transversal, que impide establecer relaciones causales, y el uso de un muestreo no probabilístico. Futuras investigaciones podrían ampliar estos resultados mediante diseños longitudinales y enfoques cualitativos que permitan comprender con mayor profundidad el papel de la IA en el aprendizaje de las matemáticas.

Referencias

- Bond, M., Khosravi, H., Laat, M. de, Bergdahl, N., Negrea, V., Oxley, E., Pham, P., Chong, S. W. y Siemens, G. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*, 21(1). <https://doi.org/10.1186/s41239-023-00436-z>
- Hossein-Mohand, H. y Hossein-Mohand, H. (2023). Influence of motivation on the perception of mathematics by secondary school students. *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.1111600>
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T. y Stadler, M. (2023). ChatGPT for good? On Opportunities and Challenges of Large Language Models for Education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- García-Alonso, I., Sosa-Martín, D. N. y García-Díaz, A. (2021). Actitudes hacia las Matemáticas en Secundaria: Análisis exploratorio. En P. D. Diago, D. F. Yáñez, M. T. González-Astudillo y D. Carrillo (Eds.), *Investigación en Educación Matemática XXIV* (pp. 287-294). SEIEM.
- Hair, J. F., Black, W. C., Babin, B. J. y Anderson, R. E. (2019). *Multivariate data analysis* (8.ª ed.). Cengage.
- Kim, Y., Brady, A. C. y Wolters, C. A. (2020). College students' regulation of cognition, motivation, behavior, and context: Distinct or overlapping processes? *Learning and Individual Differences*, 80, 101872. <https://doi.org/10.1016/j.lindif.2020.101872>
- Lazarides, R., Fauth, B., Gaspard, H. y Göllner, R. (2021). Teacher self-efficacy and enthusiasm: Relations to changes in student-perceived teaching quality at the beginning of secondary education. *Learning and Instruction*, 73, 101435. <https://doi.org/10.1016/j.learninstruc.2020.101435>
- Niss, M. y Højgaard, T. (2019). Mathematical competencies revisited. *Educational Studies in Mathematics*, 102, 9-28. <https://doi.org/10.1007/s10649-019-09903-9>
- Schukajlow, S., Rakoczy, K. y Pekrun, R. (2023). Emotions and motivation in mathematics education: Where we are today and where we need to go. *ZDM - Mathematics Education*, 55, 249-267. <https://doi.org/10.1007/s11858-022-01463-2>
- Tabachnick, B. G. y Fidell, L. S. (2019). *Using multivariate statistics* (7.ª ed.). Pearson.
- Van Vaerenbergh, S. y Pérez-Suay, A. (2021). Inteligencia artificial para la didáctica de las matemáticas: resumen y taxonomía. En P. D. Diago, D. F. Yáñez, M. T. González-Astudillo y D. Carrillo (Eds.), *Investigación en Educación Matemática XXIV* (p. 682). SEIEM.
- Widlund, A., Tuominen, H. y Korhonen, J. (2024). Motivational profiles in mathematics - stability and links with educational and emotional outcomes. *Contemporary Educational Psychology*, 76, 102256. <https://doi.org/10.1016/j.cedpsych.2024.102256>
- Zawacki-Richter, O., Marín, V. I., Bond, M. y Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education - where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1). <https://doi.org/10.1186/s41239-019-0171-0>