

CARACTERIZACIÓN DE PERFILES MOTIVACIONALES SOBRE LA FORMULACIÓN DE PROBLEMAS Y SOBRE EL USO DE IA EN FUTUROS MAESTROS DE PRIMARIA

Characterization of motivational profiles on problem posing and on AI use in pre-service elementary school teachers

Embid, S. y Perdomo-Díaz, J.

Universidad de La Laguna

Resumen

Este estudio explora posibles configuraciones en los perfiles motivacionales de 175 futuros maestros de primaria en relación con la formulación de problemas matemáticos (FP) y el uso de inteligencia artificial (IA) generativa. Para ello, se consideran sus percepciones de autoeficacia, utilidad y costes al enfrentar cada una de estas dos prácticas. Utilizando el cuestionario ForPro-IA y un análisis de clusterización mediante el algoritmo k-medias con distancia euclídea, se identificaron tres perfiles motivacionales para la FP y cuatro perfiles para la IA generativa. Como aporte adicional, se propone diseñar acciones formativas grupales integrando participantes de cada perfil para favorecer el desarrollo de disposiciones más favorables hacia ambas prácticas.

Palabras clave: *inteligencia artificial, formulación de problemas, creencias motivacionales.*

Abstract

This study explores possible configurations in the motivational profiles of 175 prospective elementary school teachers related to mathematical problem posing (PP) and the use of generative artificial intelligence (GenAI). For this purpose, their perceptions of self-efficacy, usefulness, and costs when facing each of these two practices are considered. Using the ForPro-IA questionnaire and a clustering analysis with the k-means algorithm, three motivational profiles were identified for PP and four profiles for GenAI. As an additional contribution, it is proposed to design group training actions integrating participants of each profile to favor the development of more favorable dispositions towards both practices.

Keywords: *artificial intelligence, problem posing, motivational beliefs.*

INTRODUCCIÓN

Los docentes recurren con frecuencia a libros de texto para seleccionar problemas, aunque también los crean o adaptan en función de las necesidades de sus estudiantes (Son y Diletti, 2017). En estos procesos de formulación de problemas (FP), la inteligencia artificial (IA) generativa puede convertirse en un aliado (Kim et al., 2025). Factores como la formación previa del docente, su experiencia profesional o sus creencias influyen en su manera de relacionarse con los recursos (Lupiáñez et al., 2024). Entre las creencias que intervienen se encuentran las creencias motivacionales (Giaconi et al., 2018), que se asientan en aspectos como la percepción de autoeficacia, de utilidad o de los costes asociados a enfrentar una tarea concreta (Bandura, 1997; Eccles y Wigfield, 2002). Así, el compromiso y la disposición a adoptar tanto la FP como el uso de IA generativa e integrarlas en el aula dependerán de las creencias motivacionales del docente acerca de estas dos prácticas. En el caso de la FP, la investigación sobre creencias motivacionales es todavía limitada, aunque se han identificado factores que vinculan la autoeficacia con la calidad de los problemas formulados

(Krawitz et al., 2025). Respecto al uso de IA generativa, los estudios se centran en su aplicación para la FP (Embid y Perdomo-Díaz, 2024; Kim et al., 2025), con escasa atención al dominio afectivo. El objetivo de este trabajo es estudiar los perfiles motivacionales de futuros maestros de educación primaria en relación con la FP y el uso de IA generativa. Esto permite profundizar en los resultados obtenidos en un trabajo previo sobre las creencias motivacionales de maestros en formación acerca de estas prácticas (Embid et al., aceptado).

MARCO CONCEPTUAL

El dominio afectivo engloba el conjunto de creencias, actitudes y emociones de un individuo (McLeod, 1989). Cada una de estas dimensiones constituye a su vez un subdominio con una complejidad propia. Dentro de este ámbito, las creencias motivacionales representan un tipo específico de creencias vinculadas a la percepción que el individuo tiene sobre distintos aspectos de una tarea, especialmente en relación con su autoeficacia, la utilidad que le atribuye y los costes que percibe al realizarla (Giaconi et al., 2018).

Nuestra investigación se articula en dos marcos teóricos complementarios que guían la conceptualización de la autoeficacia, la utilidad y los costes percibidos: la Teoría de Expectativa-Valor (Eccles y Wigfield, 2002) y la Teoría Social Cognitiva (Bandura, 1997). Desde la Teoría Social Cognitiva, la autoeficacia se entiende como la confianza en la propia capacidad para ejecutar una tarea con éxito (Bandura, 1997). Por su parte, la Teoría de Expectativa-Valor define la utilidad como el valor asignado a una tarea en función de su relevancia para alcanzar metas personales o profesionales, y los costes percibidos como las posibles pérdidas asociadas a la realización de dicha tarea, tales como el esfuerzo requerido, el tiempo invertido o el riesgo de fracaso (Eccles y Wigfield, 2002). Estos tres componentes —autoeficacia, utilidad y costes percibidos— interactúan entre sí y condicionan la disposición del sujeto a implicarse en tareas concretas. En el caso de nuestro estudio, dichas tareas son la formulación de problemas matemáticos y el uso de herramientas de inteligencia artificial generativa. Así, las decisiones profesionales de los futuros docentes pueden explicarse a través de dichas componentes que forman parte de sus creencias motivacionales (Giaconi et al., 2018). Por ejemplo, una elevada autoeficacia suele relacionarse con una mayor persistencia frente a los desafíos; una alta percepción de utilidad actúa como incentivo para la acción; y unos costes percibidos elevados pueden actuar como barreras inhibitorias (Bandura, 1997; Eccles y Wigfield, 2002). Así, características asociadas a una tarea, como la utilidad percibida, pueden adquirir un valor positivo, y otras como los costes percibidos, negativo (Eccles y Wigfield, 2002).

Las creencias motivacionales constituyen el núcleo de nuestro análisis y nos permiten identificar distintos perfiles motivacionales en función de los tres componentes teóricos definidos.

OBJETIVOS

A partir de lo anterior, se establecen los siguientes objetivos específicos para esta investigación:

1. Identificar y caracterizar perfiles motivacionales de futuros docentes de educación primaria en función de sus percepciones de autoeficacia, utilidad y coste percibido respecto a la formulación de problemas matemáticos.
2. Identificar y caracterizar perfiles motivacionales de futuros docentes de educación primaria en función de sus percepciones de autoeficacia, utilidad y coste percibido respecto a la aplicación de inteligencia artificial generativa en educación matemática.

METODOLOGÍA

Presentamos un estudio descriptivo, exploratorio, no experimental, en el que empleamos métodos cuantitativos de análisis (Creswell, 2012).

Participantes e instrumento

La investigación se llevó a cabo con una muestra por conveniencia no probabilística, conformada por 175 alumnos de último año del Grado en Maestro en Educación Primaria de la Universidad de La Laguna. La formación inicial de los participantes en formulación de problemas se circunscribe a un taller de 4 horas impartido durante el grado. En relación con el uso de la inteligencia artificial, no se tiene constancia de que estos alumnos hayan obtenido capacitación formal, ya sea para un uso general o particular en la enseñanza de las matemáticas. La información aportada por los participantes indica que el 56,6% usa ChatGPT al menos una vez por semana y el 18,9% a diario.

Los participantes respondieron voluntariamente al cuestionario ForPro-IA, instrumento que presenta evidencias de validez para su uso en esta muestra (Embid et al., aceptado). Este cuestionario ad hoc se diseñó en el marco de un proyecto aprobado por el comité de ética de la universidad. Los participantes firmaron un consentimiento informado que garantizaba la confidencialidad de sus respuestas y su uso exclusivo con fines de investigación. El estudio se centra en las respuestas de los futuros docentes a una parte de dicho cuestionario que abarca 6 dimensiones (Tabla 1), tres relacionadas con la formulación de problemas (AUFP, CPFP, UTFP) y las otras tres con la aplicación de inteligencia artificial en educación matemática (AUIA, CPIA, UTIA). Las dimensiones se corresponden con la autoeficacia (AU), los costos percibidos (CP) y la utilidad (UT). Cada ítem se evaluó con una escala Likert (1 = totalmente en desacuerdo, 2 = en desacuerdo, 3 = de acuerdo y 4 = totalmente de acuerdo).

Tabla 3

Ítems con evidencias de validez de las seis dimensiones del cuestionario ForPro-IA

Dimensión	Ítem	Descripción
AUFP		Considero que sabría formular problemas de primaria a partir de...
	1	datos numéricos.
	2	operaciones.
	3	contextos reales o imaginarios.
	4	viñetas o imágenes.
CPFP	5	otros problemas.
		Para un docente, formular problemas matemáticos de educación primaria...
	1	es muy difícil.
	2	supone demasiado esfuerzo.
	3	requiere mucho tiempo.
UTFP	4	genera inquietud por miedo a fracasar.
		Formular problemas matemáticos es útil para...
	1	conectar ideas matemáticas.
	2	desarrollar el razonamiento matemático.
	3	detectar dificultades de los estudiantes.
	4	trabajar dificultades de aprendizaje.
AUIA	5	atender a la diversidad del aula.
	6	trabajar las emociones de los estudiantes en relación con las matemáticas.
		Considero que sabría usar chatbots para...
	2	resolver dudas sobre conceptos matemáticos.
	3	resolver ejercicios de matemáticas.
	4	resolver problemas matemáticos.
CPIA	5	comprobar soluciones de problemas matemáticos.
	6	formulación de problemas matemáticos.
		Para un docente de educación primaria, usar chatbots con fines educativos en matemáticas...
	1	es muy difícil.
	2	supone demasiado esfuerzo.
	3	requiere mucho tiempo.

UTIA	En la formulación de problemas matemáticos para educación primaria, los chatbots son útiles para...
3	incluir contextos personalizados.
4	atender a los objetivos del currículo.
5	elaborar adaptaciones a distintos niveles.
6	desarrollar el razonamiento matemático.

Nota. La numeración no es correlativa por exclusión de ítems no validados (Embid et al., aceptado).

Proceso de análisis de los datos

Para identificar los perfiles motivacionales, se utilizaron seis variables continuas construidas a partir del promedio de las puntuaciones de los ítems que componen cada una de las dimensiones evaluadas (Embid et al., aceptado). Los perfiles se generaron mediante la creación de clústeres con el método *k-medias* (*k-means*) y distancia euclídea (Flynt y Dean, 2016). El número óptimo de clústeres, con *k* entre 2 y 6, se determinó siguiendo la regla de la mayoría (*majority rule*) propuesta por Charrad et al. (2014), contrastando los valores más frecuentes entre los índices evaluados por el paquete NbCluster en R 4.4.2. Para discriminar entre soluciones con diferente número de clústeres, se comparó la suma total de cuadrados intraclúster (*tot.withinss*), donde valores más bajos indican más similitud entre individuos dentro de un clúster, y la suma de cuadrados interclúster (*betweenss*), donde valores más altos reflejan una mayor diferenciación entre clústeres (Flynt y Dean, 2016).

Por último, se aplicó la prueba no paramétrica ANOVA de Kruskal-Wallis para comparar las puntuaciones por dimensión entre los perfiles identificados, con un nivel de significación de 0,05. El tamaño del efecto en la comparación (ε^2) se interpretó según los criterios de Cohen (1988), considerando efectos pequeños ($0,01 \leq \varepsilon^2 < 0,06$), moderados ($0,06 \leq \varepsilon^2 < 0,14$) y grandes ($\varepsilon^2 \geq 0,14$). Los análisis y gráficos estadísticos, así como la descripción detallada de los ítems para su estudio, se llevaron a cabo utilizando el software Jamovi en su versión 2.6.26 y Excel versión 2502.

RESULTADOS

Perfiles motivacionales respecto de la formulación de problemas matemáticos

Para las tres dimensiones asociadas a la FP, los índices evaluados por NbCluster sugirieron soluciones con 3 y 2 clústeres (35% y 30%, respectivamente). La solución con 3 clústeres mostró una mayor cohesión interna (*tot.withinss* = 72,54) y una mejor separación entre grupos (*betweenss* = 54,06) que la solución con 2 clústeres (*tot.withinss* = 88,07; *betweenss* = 38,52), por lo que se eligió como solución óptima. Estos tres perfiles mostraron diferencias significativas en las tres dimensiones evaluadas, con efectos grandes en todos los casos (Tabla 2).

Tabla 2

Perfiles identificados en las dimensiones de formulación de problemas

Dimensión	Perfil 1	Perfil 2	Perfil 3	χ^2 (gl)	p	ε^2
AUFP	3,50 (0,40)	3,17 (0,36)	2,97 (0,46)	39,0 (2)	<0,001	0,224
CPFP	1,55 (0,37)	2,54 (0,39)	2,42 (0,37)	87,9 (2)	<0,001	0,505
UTFP	3,45 (0,38)	3,68 (0,23)	2,91 (0,34)	104,3 (2)	<0,001	0,599


Nota. Se presenta la media y la desviación estándar (entre paréntesis) para cada dimensión.

El Perfil 1 (n=41) se caracteriza por presentar las puntuaciones más elevadas y homogéneas en relación con la autoeficacia en formulación de problemas y las más bajas en cuanto al coste percibido (Figura 1). En relación con la percepción de utilidad, las puntuaciones en varios de los ítems son similares al Perfil 2. Los participantes que componen el Perfil 1, asignan una mayor puntuación a los ítems de autoeficacia para formular problemas en contextos reales ($M_{AUFP3} = 3,68$, $DE_{AUFP3} = 0,47$) y a la utilidad percibida para desarrollar el razonamiento matemático ($M_{UTFP2} = 3,83$, $DE_{UTFP2} = 0,47$).

Por otro lado, muestran la menor percepción de costes asociados a la FP, especialmente en relación con el esfuerzo ($M_{CPFP2} = 1,39$, $DE_{UTFP2} = 0,49$).

Figura 1

Promedios por ítems según los perfiles identificados en las dimensiones de formulación de problemas



Los participantes del Perfil 2 ($n=45$) presentan puntuaciones más elevadas y homogéneas en relación con la percepción de utilidad de la FP, valorando especialmente la utilidad para detectar dificultades de aprendizaje ($M_{UTFP3} = 3,80$, $DE_{UTFP3} = 0,46$) y trabajarlas ($M_{UTFP4} = 3,78$, $DE_{UTFP4} = 0,47$). También son quienes perciben un mayor coste, especialmente en cuanto al tiempo que requiere ($M_{CPFP3} = 2,60$, $DE_{CPFP3} = 0,58$). En relación con su percepción de autoeficacia, se mantienen en un nivel intermedio entre los otros dos perfiles.

Por último, el Perfil 3 ($n=89$) se caracteriza por una percepción inferior de autoeficacia y de utilidad de la FP y una percepción casi tan alta del coste asociado como el Perfil 2. Las puntuaciones más bajas se dan en los ítems que evalúan la autoeficacia para formular problemas a partir de viñetas o imágenes ($M_{AUF4} = 2,87$, $DE_{AUF4} = 0,64$) y a partir de otros problemas ($M_{AUF5} = 2,88$, $DE_{AUF5} = 0,62$), así como los ítems sobre la utilidad para atender a la diversidad ($M_{UTFP5} = 2,57$, $DE_{UTFP5} = 0,66$) y para trabajar emociones en relación con las matemáticas ($M_{UTFP6} = 2,52$, $DE_{UTFP6} = 0,69$).

Perfiles motivacionales respecto del uso de inteligencia artificial generativa

En el caso de la IA, los índices calculados por NbCluster nos sugirieron soluciones con 2 clústeres (30,4%) y 4 clústeres (26,1%). La solución con 4 clústeres presentó la mayor diferenciación entre grupos ($betweenss = 65,28$ vs $betweenss = 58,66$) y la mayor similitud entre individuos dentro de un mismo grupo ($tot.withinss = 61,32$ vs $tot.withinss = 123,22$) por lo que se eligió como solución óptima. Estos perfiles mostraron diferencias significativas en dos de las tres dimensiones, autoeficacia y costes, con efectos moderados en ambas (Tabla 3).

Tabla 3

Perfiles identificados en las dimensiones de inteligencia artificial generativa


Dimensión	Perfil 1	Perfil 2	Perfil 3	Perfil 4	χ^2 (gl)	p	ε^2
AUIA	2,76 (0,65)	3,33 (0,65)	3,13 (0,64)	2,98 (0,50)	15,04 (3)	0,002*	0,0865
CPIA	1,91 (0,48)	1,53 (0,50)	1,96 (0,58)	2,00 (0,54)	14,45 (3)	0,002*	0,0830
UTIA	2,73 (0,44)	2,98 (0,60)	2,91 (0,68)	2,69 (0,60)	6,44 (3)	0,092	0,0370

Nota. Se presenta la media y la desviación estándar (entre paréntesis) para cada dimensión.

La principal característica que diferencia al Perfil 1 ($n=67$) del resto es que presenta las puntuaciones más bajas en relación con la autoeficacia en el uso de la IA (Figura 2), estando la mayor diferencia con el resto de los perfiles en la autoeficacia para comprobar soluciones de problemas matemáticos ($M_{AUIA2} = 2,79$, $DE_{AUIA2} = 0,75$) y para formular problemas matemáticos ($M_{AUIA6} = 2,81$, $DE_{AUIA6} = 0,74$).

Figura 2

Promedios por ítems según los perfiles identificados en las dimensiones de inteligencia artificial



El Perfil 2 ($n=30$) presenta puntuaciones ligeramente favorables al resto de perfiles en la mayoría de los ítems, destacando el referido a autoeficacia en el uso de IA para la formulación de problemas ($M_{AUIA6} = 3,60$, $DE_{AUIA6} = 0,50$). Los costes percibidos son los más bajos entre los perfiles, con el mismo promedio de puntuaciones en esfuerzo ($M_{CPIA2} = 1,50$, $DE_{CPIA2} = 0,51$) y tiempo requerido ($M_{CPIA3} = 1,50$, $DE_{CPIA3} = 0,57$).

El Perfil 3 ($n=45$) es cercano al Perfil 2 en términos de autoeficacia y utilidad, pero sus integrantes asocian un coste mayor al uso de la IA. El coste promedio asociado a la dificultad coincide con el de los participantes del perfil 1, siendo el más elevado ($M_{CPIA1} = 2,07$, $DE_{CPIA1} = 0,80$). También el promedio de percepción de utilidad para incluir contextos personalizados al formular problemas es el más elevado entre los perfiles identificados ($M_{UTIA3} = 2,96$, $DE_{UTIA3} = 0,82$).

Finalmente, el Perfil 4 ($n=33$) se distingue del resto por ser el que presenta las puntuaciones más bajas en los ítems de utilidad, destacando la utilidad para incluir contextos personalizados ($M_{UTIA3} = 2,52$, $DE_{UTIA3} = 0,83$) y atender a los objetivos del currículo ($M_{UTIA4} = 2,70$, $DE_{UTIA4} = 0,77$). También presenta la percepción más alta en relación con el promedio de coste en el tiempo que requiere el uso de chatbots con fines educativos en matemáticas ($M_{CPIA3} = 2,09$, $DE_{CPIA3} = 0,68$).

REFLEXIONES FINALES

Este estudio ha permitido identificar perfiles motivacionales a partir de las percepciones de autoeficacia, de utilidad y de los costes asociados a formular problemas y usar inteligencia artificial de 175 futuros docentes de primaria. La información obtenida puede orientar el diseño de programas formativos donde se tengan en cuenta las características afectivas y particularidades de estos futuros docentes a la hora de relacionarse con cualquiera de estas dos prácticas.

Respecto a la práctica de formulación de problemas (objetivo 1), se identificaron tres perfiles motivacionales. El Perfil 1 destaca por puntuaciones favorables en todos los aspectos, mostrando una alta percepción de autoeficacia y utilidad de la formulación de problemas, junto con una baja percepción de los costes asociados a esta práctica. Estos resultados indican que los participantes de este perfil tienen una visión muy positiva de la formulación de problemas, lo que podría facilitar su adopción y sostenibilidad en el futuro, como sugiere el modelo de Eccles y Wigfield (2002). Sin embargo, son el grupo menos numeroso de los tres, componiendo un 23,43% de la muestra. El Perfil 2, aunque también percibe la formulación de problemas como altamente útil, muestra una mayor percepción de los costes, especialmente en relación con el tiempo y la ansiedad por el fracaso. Esto podría implicar un desafío en términos de perseverancia, ya que la relación coste-beneficio no necesariamente favorece el mantenimiento de la práctica. La autoeficacia presenta valores intermedios, sin ser tan altos como los del Perfil 1. Por último, el Perfil 3, que representa a casi la mitad de los futuros maestros de primaria que participaron en este estudio, se caracteriza por tener las puntuaciones más bajas en utilidad y autoeficacia. Este grupo, en particular, podría ser el más susceptible a la desmotivación, dado que presenta la menor confianza en su capacidad para formular problemas matemáticos, la menor utilidad percibida y los costes asociados son moderados (Bandura,

1997; Eccles y Wigfield, 2002). Desde una perspectiva formativa, la identificación de estos perfiles permite diseñar estrategias que fomenten la interacción entre futuros docentes con diferentes niveles de motivación (Krawitz et al., 2025). Una opción es promover el trabajo colaborativo en grupos heterogéneos, integrando participantes de cada perfil para favorecer el desarrollo de disposiciones más favorables hacia la FP. Los participantes del Perfil 1 pueden transmitir sus percepciones de autoeficacia, utilidad y costes a quienes pudiesen presentar menor predisposición, el Perfil 3. A su vez, los integrantes del Perfil 2 pueden sensibilizar a los integrantes de los otros dos perfiles sobre la importancia del esfuerzo y la perseverancia en esta práctica. En este sentido, reforzar el dominio afectivo en la formación docente puede ayudar a consolidar disposiciones favorables hacia las matemáticas, como destacan Marbán et al. (2020).

En cuanto al uso de inteligencia artificial (objetivo 2), los resultados sugieren la existencia de cuatro perfiles con diferencias significativas en autoeficacia y costes percibidos, aunque no en utilidad (Tabla 3). El Perfil 2 reúne a los futuros maestros de primaria con mayor confianza en sus capacidades, mayor percepción de utilidad y menor percepción de costes asociados. En el extremo opuesto, el Perfil 4 presenta los valores más bajos en utilidad, lo que podría derivar en una mayor reticencia hacia el uso de IA generativa. Los Perfiles 1 y 3, que representan a la mayoría de la muestra, reflejan posturas intermedias. El Perfil 1 muestra una autoeficacia y utilidad moderadas, con costes percibidos en un nivel intermedio, mientras que el Perfil 3 se distingue por una percepción de utilidad relativamente alta, acompañada de una autoeficacia moderada y una percepción variable de los costes. La distribución de los perfiles sugiere que la mayoría de los participantes mantiene una postura cautelosa frente a la IA, posiblemente debido a experiencias previas que generan dudas sobre su eficacia o fiabilidad (Embid y Perdomo-Díaz, 2024). Desde la formación inicial, podría fomentarse una percepción más positiva proporcionando experiencias guiadas y estructuradas que permitan explorar el potencial de la IA, tal como proponen Krawitz et al. (2025). Además, el trabajo colaborativo entre participantes con diferentes perfiles podría facilitar la integración gradual de estas herramientas, especialmente si se refuerzan los beneficios asociados a su uso para la personalización del aprendizaje y la atención a la diversidad.

Esta investigación se suma a otras que manifiestan la necesidad de diseñar tareas formativas que permitan desarrollar habilidades de formulación de problemas (Chico et al., 2022; Leavy y Hourigan, 2022), aportando una reflexión sobre el trabajo colaborativo entre perfiles motivacionales opuestos y la posible incorporación de inteligencia artificial en el proceso. Sin embargo, existen limitaciones metodológicas que afectan el alcance de los resultados. Entre estas limitaciones se encuentra el uso de la escala Likert de cuatro puntos, que restringe la captación de matices en las respuestas, o la elección del método k-medias para la formación de clústeres, que presenta sensibilidad a valores extremos (Charrad et al., 2014). También el tamaño y las características específicas de la muestra a la que se aplicó el cuestionario ForPro-IA (Embid et al., aceptado). Además, las respuestas en cuestionarios autorreportados pueden estar sesgadas por deseabilidad social, una tendencia documentada en estudios previos (Woolfolk Hoy et al., 2009). Futuras investigaciones deberían incorporar variables adicionales para una caracterización más precisa de los perfiles motivacionales. Esto permitiría el refinamiento del instrumento de medición, mejorando el análisis de creencias motivacionales en la formación inicial docente en FP e IA generativa.

Agradecimientos

Este trabajo ha sido realizado gracias al Proyecto PID2022-139007NB-I00 y al contrato predoctoral PREP2022-000959 financiados por MCIN/AEI /10.13039/501100011033 /FEDER, UE y FSE+.

Referencias

Bandura, A. (1997). *Self-efficacy: The exercise of control*. W. H. Freeman.

- Charrad, M., Ghazzali, N., Boiteau, V. y Niknafs, A. (2014). NbClust: An R Package for Determining the Relevant Number of Clusters in a Data Set. *Journal of Statistical Software*, 61(6), 1–36. <https://doi.org/10.18637/jss.v061.i06>
- Chico, J., Montes, M. y Badillo, E. (2022). Transformaciones de la información en la formulación de problemas: una mirada hacia los futuros maestros. En T. F. Blanco, C. Núñez-García, M. C. Cañadas y J. A. González-Calero (Eds.), *Investigación en Educación Matemática XXV* (pp. 219-227). SEIEM.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences*. Routledge.
- Creswell, J. W. (2012). *Educational research: Planning, conducting, and evaluating quantitative and qualitative research*. Pearson.
- Eccles, J. S. y Wigfield, A. (2002). Motivational beliefs, values, and goals. *Annual Review of Psychology*, 53, 109-132. <https://doi.org/10.1146/annurev.psych.53.100901.135153>
- Embid, S. y Perdomo-Díaz, J. (2024). Evaluación del potencial de distintos chatbots para la formulación de problemas matemáticos. *Formación del Profesorado e Investigación en Educación Matemática*, 16, 41-58.
- Embid, S., Perdomo-Díaz, J. y Giaconi, V. (aceptado). Formulación de problemas y uso de IA: Creencias motivacionales en futuros docentes de primaria. *Avances de Investigación en Educación Matemática*.
- Flynt, A. y Dean, N. (2016). A survey of popular r packages for cluster analysis. *Journal of Educational and Behavioral Statistics*, 41(2), 205-225. <https://doi.org/10.3102/1076998616631743>
- Giaconi, V., Perdomo-Díaz, J., Cerda, G. y Saadati, F. (2018). Prácticas docentes, autoeficacia y valor en relación con la resolución de problemas de matemáticas: Diseño y validación de un cuestionario. *Enseñanza de las Ciencias*, 36(3). <https://doi.org/10.5565/REV/ENSCIENCIAS.2351>
- Kim, Y. R., Park, M. S. y Joung, E. (2025). Exploring the integration of artificial intelligence in math education: Preservice Teachers' experiences and reflections on problem-posing activities with ChatGPT. *School Science and Mathematics*, 1-15. <https://doi.org/10.1111/ssm.18336>
- Krawitz, J., Schukajlow, S. y Hartmann, L. (2025). Does problem posing affect self-efficacy, task value, and performance in mathematical modelling? *Educational Studies in Mathematics*. <https://doi.org/10.1007/s10649-025-10385-1>
- Leavy, A. y Hourigan, M. (2022). The Framework for Posing Elementary Mathematics Problems (F-PosE): Supporting teachers to evaluate and select problems for use in elementary mathematics. *Educational Studies in Mathematics*, 111(1), 147-176. <https://doi.org/10.1007/s10649-022-10155-3>
- Lupiañez, J. L., Olivares, D. y Segovia, I. (2024). Examining the role played by resources, goals and orientations in primary teachers' decision-making for problem-solving lesson plans. *ZDM–Mathematics Education*, 56, 1153–1167. <https://doi.org/10.1007/s11858-024-01614-7>
- Marbán, J. M., Palacios, A. y Maroto, A. (2020). Desarrollo del domino afectivo matemático en la formación inicial de maestros de primaria. *Avances De Investigación En Educación Matemática*, 18, 73-86. <https://doi.org/10.35763/aiem.v0i18.286>
- McLeod, D. B. (1989). Beliefs, attitudes, and emotions: New views of affect in mathematics education. En D. B. McLeod y V. M. Adams (Eds.), *Affect and mathematical problem solving: A new perspective* (pp. 245-258). Springer. https://doi.org/10.1007/978-1-4612-3614-6_17
- Son, J. W. y Diletti, J. (2017). What can we learn from textbook analysis? En J.-W. Son, T. Watanabe y J.-J. Lo (Eds.), *What matters? Research trends in international comparative studies in mathematics education* (pp. 3-32). Springer International Publishing. https://doi.org/10.1007/978-3-319-51187-0_1
- Woolfolk-Hoy, A., Hoy, W. K. y Davis, H. A. (2009). Teachers' self-efficacy beliefs. En K. R. Wentzel y A. Wigfield (eds.), *Handbook of motivation in school* (pp. 627-653). Routledge.