

OPTIMIZACIÓN DEL EMPAREJAMIENTO TUTOR-ESTUDIANTE CON INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR

OPTIMIZING TUTOR-STUDENT MATCHING USING ARTIFICIAL INTELLIGENCE IN HIGHER EDUCATION

J. I. Campos Bravo¹
E. Ramírez Lazos²
J. C. Ortiz León³
J. A. López Hernández⁴

RESUMEN

La integración de la inteligencia artificial (IA) en la educación superior ha abierto nuevas oportunidades para optimizar las experiencias de aprendizaje. Este estudio propone un enfoque innovador para la tutoría estudiantil mediante el uso de técnicas de IA, específicamente algoritmos evolutivos y redes neuronales. Se realizará una encuesta para determinar los perfiles de aprendizaje de los estudiantes, que servirá como base para un sistema inteligente de asignación de tutores a largo plazo. Los datos recopilados serán analizados utilizando técnicas de aprendizaje automático para clasificar a los estudiantes en distintas categorías de aprendizaje. La metodología propuesta tiene como objetivo mejorar los resultados del aprendizaje estudiantil al emparejar a los alumnos con los tutores más adecuados según sus preferencias cognitivas y metodológicas. El estudio también aborda las consideraciones éticas relacionadas con la privacidad de los datos y la toma de decisiones basada en IA. Se espera que los hallazgos contribuyan al desarrollo de estrategias educativas adaptativas y basadas en datos en las instituciones de educación superior.

ABSTRACT

The integration of artificial intelligence (AI) in higher education has opened new avenues for optimizing learning experiences. This study proposes a novel approach to student tutoring by leveraging AI techniques, specifically evolutionary algorithms and neural networks. A survey will be conducted to determine students' learning profiles, which will serve as the foundation for a future intelligent tutor assignment system. The collected data will be analyzed using machine learning techniques to classify students into distinct learning categories. Evolutionary algorithms will be employed to optimize tutor-student pairings, ensuring personalized and efficient guidance. The proposed methodology aims to enhance student learning outcomes by matching learners with the most suitable tutors based on their cognitive and methodological preferences. The study also discusses the ethical considerations surrounding data privacy and AI-driven decision-making. The findings are expected to contribute to the development of adaptive and data-driven educational strategies in higher education institutions.

ANTECEDENTES

La inteligencia artificial en la educación superior

La integración de la inteligencia artificial (IA) en la educación superior ha evolucionado significativamente en las últimas décadas, transformando la manera en que estudiantes y docentes interactúan con el conocimiento.

En sus inicios, las aplicaciones de la IA se limitaban a tareas como la automatización de evaluaciones y la gestión de contenidos en entornos virtuales de aprendizaje. Sin embargo,

¹ Profesor de Asignatura. Facultad de Estudios Superiores Aragón. Universidad Nacional Autónoma de México (UNAM) jorgecampos47@aragon.unam.mx

² Profesor de Asignatura. Facultad de Estudios Superiores Aragón. UNAM estebanlazos28@aragon.unam.mx

³ Profesor de Asignatura. Facultad de Estudios Superiores Aragón. UNAM juanortizk7@aragon.unam.mx

⁴ Profesor de Asignatura. Facultad de Estudios Superiores Aragón. UNAM jorgelopez91@aragon.unam.mx

con el avance de la tecnología y la disponibilidad de grandes volúmenes de datos educativos, la IA ha ampliado su alcance, permitiendo la implementación de sistemas adaptativos que personalizan la experiencia de aprendizaje según las necesidades individuales de cada estudiante.

Actualmente, la IA está redefiniendo conceptos tradicionales en la educación superior. Herramientas como asistentes virtuales, plataformas de tutoría inteligente y sistemas de análisis predictivo están siendo utilizadas para mejorar la eficiencia y la calidad del proceso educativo. Estas innovaciones no solo optimizan la gestión académica, sino que también permiten una mayor inclusión al ofrecer soluciones personalizadas para estudiantes con diversos estilos de aprendizaje o necesidades especiales (Luckin et al., 2016, Woolf, 2010, Zawacki-Richter et al., 2019). La importancia actual de la IA radica en su capacidad para transformar el modelo tradicional de educación hacia uno más flexible y centrado en el estudiante, promoviendo una educación accesible, equitativa y orientada al futuro.

Algoritmos evolutivos en educación

Los algoritmos evolutivos, inspirados en los procesos naturales de selección y evolución, han encontrado aplicaciones significativas en el ámbito educativo. Estas técnicas de inteligencia artificial se basan en principios como la mutación, la recombinación y la selección para resolver problemas complejos mediante la búsqueda de soluciones óptimas en espacios grandes de posibilidades (Mitchell, 1998).

En educación, los algoritmos evolutivos se han utilizado principalmente para la optimización de recursos y procesos. Un ejemplo destacado es su aplicación en el diseño de horarios académicos, donde se enfrentan restricciones como disponibilidad de docentes, capacidad de aulas y preferencias de los estudiantes. Otro uso relevante de los algoritmos evolutivos en la educación es el desarrollo de sistemas que evalúan y mejoran continuamente el diseño curricular. Mediante la simulación y evaluación de diferentes configuraciones curriculares, estos algoritmos pueden identificar las combinaciones más efectivas para alcanzar los objetivos educativos.

Con el crecimiento exponencial de datos educativos disponibles, los algoritmos evolutivos también se utilizan en el análisis de grandes volúmenes de información para identificar patrones y tendencias que permitan mejorar la toma de decisiones en la gestión académica. Estas aplicaciones subrayan el potencial de los algoritmos evolutivos para abordar problemas complejos y promover la eficiencia en la educación superior.

Redes neuronales en la educación

Las redes neuronales, un componente clave de la inteligencia artificial, se inspiran en la estructura del cerebro humano para procesar información de manera eficiente (Goodfellow et al., 2016, Sazli, 2006, Schmidhuber, 2015). Estas redes consisten en capas de neuronas artificiales que trabajan en conjunto para identificar patrones, clasificar datos y realizar predicciones.

En el contexto de la educación superior, las redes neuronales han demostrado ser herramientas poderosas para analizar grandes volúmenes de datos educativos y proporcionar soluciones personalizadas (Bilal et al., 2022). Un uso destacado es su aplicación en sistemas

de tutoría inteligente, donde las redes pueden adaptarse al progreso de cada estudiante y ofrecer retroalimentación en tiempo real. Por ejemplo, plataformas de aprendizaje basadas en IA utilizan redes neuronales para recomendar materiales de estudio personalizados según las áreas de mejora de cada estudiante.

Otro campo donde las redes neuronales han mostrado su impacto es el análisis predictivo del desempeño estudiantil. Estas técnicas permiten identificar patrones en el comportamiento de los estudiantes que pueden predecir su éxito o abandono académico, facilitando la implementación de intervenciones tempranas.

Además, las redes neuronales también han sido utilizadas en el desarrollo de modelos para la evaluación automatizada de trabajos escritos, lo que reduce la carga administrativa de los docentes y mejora la eficiencia en la retroalimentación. Estas aplicaciones resaltan el potencial de las redes neuronales para transformar la educación superior al proporcionar herramientas innovadoras que optimizan tanto el aprendizaje como la enseñanza.

Sinergia entre algoritmos evolutivos y redes neuronales

La combinación de algoritmos evolutivos y redes neuronales ha dado lugar a un campo emergente conocido como neuro evolución (Stanley et al., 2019). Este enfoque utiliza algoritmos evolutivos para optimizar arquitecturas de redes neuronales y ajustar sus hiperparámetros, lo que resulta en modelos más eficientes y precisos.

En educación superior, esta sinergia ha demostrado ser útil en aplicaciones como la generación de contenidos educativos adaptativos, donde los algoritmos evolutivos ayudan a diseñar redes neuronales capaces de identificar las mejores estrategias de enseñanza para grupos heterogéneos de estudiantes. Por ejemplo, sistemas de recomendación que combinan ambas técnicas pueden predecir con mayor precisión las necesidades individuales de los estudiantes y ofrecer soluciones personalizadas.

Otro ejemplo es el uso de neuro evolución en simuladores educativos avanzados, donde se optimizan modelos para predecir resultados basados en diferentes escenarios académicos. Esto permite a las instituciones tomar decisiones informadas sobre políticas educativas y estrategias de enseñanza.

Aunque esta combinación ofrece grandes beneficios, también presenta retos, como el elevado costo computacional y la complejidad en la interpretación de los modelos resultantes. Sin embargo, los avances continuos en estas áreas prometen superar estas limitaciones, allanando el camino para una educación superior más innovadora y efectiva.

Retos y desafíos históricos

A pesar de los avances en la aplicación de la inteligencia artificial en la educación superior, existen numerosos retos que deben ser abordados para garantizar su implementación efectiva y ética. Uno de los principales desafíos es la disponibilidad y calidad de los datos educativos. Muchas instituciones carecen de infraestructuras adecuadas para recopilar y analizar datos, lo que limita el alcance de las soluciones basadas en IA.

Otro reto importante es el costo asociado a la implementación de estas tecnologías, ya que el desarrollo y despliegue de modelos avanzados requiere recursos computacionales significativos. Además, la falta de capacitación en el uso de estas herramientas representa una barrera para docentes y administradores.

Desde una perspectiva ética, surgen preocupaciones sobre la privacidad de los datos y los posibles sesgos en los modelos de IA. Es fundamental garantizar que las soluciones sean inclusivas y no perpetúen desigualdades existentes. Para ello, es necesario establecer regulaciones claras y promover una mayor transparencia en el diseño y uso de estas tecnologías.

Finalmente, la resistencia al cambio cultural en algunas instituciones también constituye un obstáculo. La adopción de tecnologías innovadoras requiere un cambio de mentalidad tanto en estudiantes como en docentes, así como un compromiso institucional hacia la modernización del sistema educativo.

Planteamiento del Problema

La tutoría en educación superior juega un papel fundamental en el éxito académico de los estudiantes, ya que proporciona apoyo personalizado para resolver dudas, desarrollar habilidades y fortalecer el aprendizaje autónomo. Sin embargo, la asignación de tutores suele realizarse de manera arbitraria o basada en criterios generales que no consideran las características individuales de los estudiantes. Esto puede generar emparejamientos poco efectivos, donde el tutor asignado no es el más adecuado para atender las necesidades específicas del alumno.

Dado el avance en la aplicación de inteligencia artificial (IA) en la educación, surge la oportunidad de mejorar este proceso mediante técnicas de aprendizaje automático y optimización. El presente estudio explora cómo los algoritmos evolutivos y las redes neuronales pueden emplearse para mejorar la asignación de tutores en educación superior, considerando los estilos de aprendizaje de los estudiantes y sus preferencias metodológicas.

Los objetivos de esta investigación son los siguientes:

1. Identificar los estilos de aprendizaje de los estudiantes mediante un modelo basado en inteligencia artificial, comparando los resultados obtenidos con su autopercepción.
2. Evaluar la eficacia de una red neuronal con optimización evolutiva para clasificar los estilos de aprendizaje de los estudiantes en función de sus respuestas a un cuestionario basado en el modelo VARK.
3. Determinar la relación entre la percepción subjetiva y los resultados obtenidos mediante IA, analizando la precisión del modelo en comparación con la autoevaluación de los estudiantes.
4. Explorar el potencial de la IA para personalizar estrategias de aprendizaje, identificando perfiles mixtos y la posibilidad de enfoques educativos adaptativos.

Las preguntas de investigación que guían este estudio son:

1. ¿Qué tan efectiva es la inteligencia artificial para predecir los estilos de aprendizaje de los estudiantes en comparación con la autopercepción de estos?

2. ¿Cómo influye la precisión del modelo en la asignación de tutores adecuados para cada estudiante?

¿Cuáles son las ventajas y limitaciones de implementar un sistema basado en IA para la asignación de tutores en educación superior?

La justificación de este estudio radica en la necesidad de optimizar los recursos educativos y mejorar la experiencia de los estudiantes mediante estrategias personalizadas. Un sistema basado en IA puede contribuir a reducir la tasa de deserción, mejorar el rendimiento académico y hacer más eficiente el proceso de tutoría. Además, al proporcionar una asignación más precisa, se fomenta una educación más equitativa y adaptativa.

Contexto de la Investigación

Este estudio se llevó a cabo en la Facultad de Estudios Superiores Aragón de la Universidad Nacional Autónoma de México (UNAM), en la carrera de Ingeniería en Computación. Se aplicó una encuesta a estudiantes de distintos semestres con el objetivo de identificar sus estilos de aprendizaje utilizando el modelo VARK (Visual, Auditivo, Lectura/Escritura y Kinestésico). Además, se exploró el uso de herramientas de IA generativa en su proceso de aprendizaje.

Los datos obtenidos fueron procesados mediante algoritmos de aprendizaje automático para analizar la distribución de los estilos de aprendizaje en la población estudiantil. Posteriormente, se implementó un modelo de red neuronal con evolución evolutiva para predecir el estilo de aprendizaje de los estudiantes en función de sus respuestas.

Para la validación del modelo, se compararon los resultados obtenidos por la red neuronal con la autopercepción de los estudiantes y la asignación de los estilos usando el modelo VARK. Finalmente, se analizaron los hallazgos en términos de su aplicabilidad en la asignación de tutores en el contexto universitario.

Limitaciones del Estudio

Si bien este estudio ofrece una aproximación innovadora a la asignación de tutores mediante IA, presenta algunas limitaciones:

1. Tamaño y diversidad de la muestra: La investigación se realizó con estudiantes de una única institución y carrera, lo que puede limitar la generalización de los resultados a otros contextos académicos.
2. Autopercepción subjetiva: La comparación entre la predicción de la IA y la autoevaluación de los estudiantes puede verse afectada por sesgos cognitivos en la percepción de su propio aprendizaje.
3. Capacidad computacional: El entrenamiento de redes neuronales y algoritmos evolutivos requiere un alto poder de cómputo, lo que puede dificultar su implementación en instituciones con recursos limitados.
4. Factores externos: La efectividad del modelo podría estar influenciada por variables no consideradas en este estudio, como el nivel de motivación de los estudiantes o su contexto socioeconómico.

METODOLOGÍA

Para alcanzar los resultados de este estudio, se diseñó un enfoque basado en inteligencia artificial con el objetivo de optimizar la asignación de tutores en función de los estilos de aprendizaje de los estudiantes. La metodología se estructuró en cuatro fases principales: diseño de la encuesta, recolección de datos, procesamiento y análisis de datos, e implementación del modelo de IA.

Diseño de la Encuesta

Se elaboró un cuestionario estructurado en dos secciones principales:

- Identificación del estilo de aprendizaje: Se utilizó el modelo VARK (Visual, Auditivo, Lectura/Escritura y Kinestésico) para clasificar a los estudiantes según sus preferencias cognitivas.
- Uso de herramientas de IA generativa: Se incluyeron preguntas para explorar la familiaridad y uso de herramientas como ChatGPT y DALL-E en su proceso de aprendizaje.

El cuestionario fue validado mediante una prueba piloto con un grupo reducido de estudiantes para garantizar su claridad y relevancia.

Recolección de Datos

La encuesta se aplicó a 216 estudiantes de la Facultad de Estudios Superiores Aragón de la UNAM, específicamente de la carrera de Ingeniería en Computación. Se empleó un formulario digital para recopilar las respuestas y almacenarlas en formato CSV para su posterior análisis.

Los datos obtenidos incluyen:

- Preferencias de aprendizaje según el modelo VARK.
- Nivel de familiaridad con herramientas de inteligencia artificial.
- Información demográfica básica para contextualizar los resultados.

Procesamiento y Análisis de Datos

Para el análisis de los datos, se siguieron los siguientes pasos:

1. Preprocesamiento de datos:
 - Conversión de respuestas cualitativas en valores numéricos.
 - Eliminación de datos inconsistentes o incompletos.
 - Normalización de los valores para su uso en algoritmos de clasificación.
2. Clasificación de estudiantes:
 - Se aplicaron algoritmos de clasificación para agrupar a los estudiantes en las cuatro categorías del modelo VARK.
 - Se realizó un análisis estadístico de la distribución de los estilos de aprendizaje en la población estudiada.
3. Evaluación de la autopercepción:
 - Se compararon los resultados obtenidos por la IA con la autoevaluación de los estudiantes.
 - Se calculó la precisión de la autopercepción en relación con la clasificación automática.

Implementación del Modelo de IA

Para predecir el estilo de aprendizaje de los estudiantes, se diseñó una red neuronal artificial combinada con un algoritmo evolutivo.

Arquitectura de la Red Neuronal

- Entradas: 14 nodos representando las respuestas del cuestionario.
- Capa oculta: 7 neuronas para capturar relaciones no lineales entre las variables.
- Salida: 4 nodos correspondientes a los estilos de aprendizaje (visual, auditivo, lectura/escritura y kinestésico).
- Función de activación: Se utilizó una función softmax en la capa de salida para asignar una probabilidad a cada estilo de aprendizaje.
- Entrenamiento: Se ejecutaron 10,000 generaciones en el algoritmo evolutivo para ajustar los pesos sinápticos y optimizar la precisión del modelo.

Validación del Modelo

Dado que no existe una clasificación "correcta" en términos absolutos para los estilos de aprendizaje, la validación del modelo se realizó comparando los resultados obtenidos por la red neuronal con los del modelo VARK tradicional basado en la autoevaluación de los estudiantes.

Para ello, se analizaron las diferencias en la distribución de los estilos de aprendizaje entre ambos enfoques:

- La encuesta VARK indicó que los estilos predominantes en la población estudiada eran visual (46.1%) y kinestésico (38.9%), con una menor representación de los estilos auditivo y lectura/escritura.
- La red neuronal, en contraste, mostró que el 56.64% de los estudiantes eran kinestésicos y solo el 27.43% eran visuales, lo que sugiere que la percepción subjetiva puede no reflejar con precisión la verdadera distribución de estilos de aprendizaje.

Adicionalmente, el modelo de IA permitió identificar perfiles de aprendizaje mixtos, un aspecto que el modelo VARK tradicional no contempla. La red neuronal asignó pesos relativos a cada estilo en lugar de realizar una clasificación binaria, revelando que el 28.32% de los estudiantes no encajaban exclusivamente en una sola categoría de aprendizaje.

En lugar de validar el modelo con una clasificación absoluta, este análisis permitió contrastar cómo la inteligencia artificial ofrece una perspectiva diferente y posiblemente más matizada de los estilos de aprendizaje. La identificación de combinaciones entre diferentes estilos sugiere que los métodos tradicionales podrían estar limitados por la subjetividad de la autoevaluación y la rigidez de su clasificación.

Visualización de Resultados

Los hallazgos fueron representados mediante gráficos de distribución y tablas comparativas que muestran:


- La proporción de estudiantes en cada categoría de aprendizaje según la encuesta.
- La clasificación obtenida mediante el modelo de IA.
- El porcentaje de coincidencia entre la autoevaluación y la predicción del modelo.

Además, se identificaron casos de aprendizaje mixto, donde los estudiantes mostraban características de más de un estilo de aprendizaje, lo que sugiere la necesidad de enfoques educativos más flexibles.

RESULTADOS

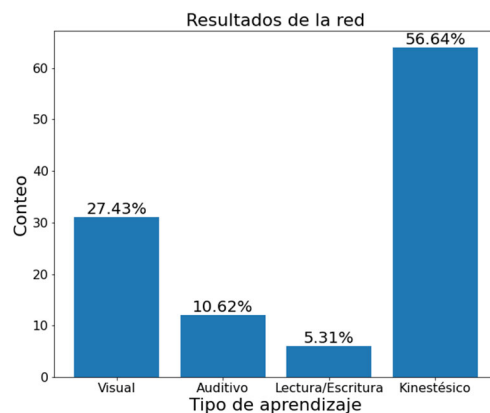
Los resultados obtenidos a partir de la encuesta aplicada a los estudiantes revelan una distribución variada de los estilos de aprendizaje predominantes. Como se observa en la Figura 1, la mayoría de los estudiantes se identificaron como visuales (46.1%) y kinestésicos (38.9%), mientras que los estilos de aprendizaje auditivo (pequeño porcentaje) y lectura/escritura (5.3%) fueron menos representados como se puede ver en la Figura 1.

Figura 1 Resultados obtenidos en la encuesta.



Por otro lado, los resultados obtenidos a través de la red neuronal mostraron una distribución diferente en cuanto a los estilos de aprendizaje predominantes. De acuerdo con el análisis del modelo, el 27.43% de los estudiantes fueron clasificados como visuales, el 10.62% como auditivos, el 5.31% como de lectura/escritura y el 56.64% como kinestésicos, como se muestra en la Figura 2. Esta discrepancia entre la percepción de los estudiantes y los resultados de la red neuronal destaca la necesidad de metodologías objetivas para evaluar el tipo de aprendizaje.

Figura 2 Resultados obtenidos a partir del entrenamiento de la red neuronal.



Un hallazgo clave de este estudio es la identificación de perfiles de aprendizaje mixtos. La red neuronal permitió determinar que un 28.32% de los estudiantes no pertenecen exclusivamente a un único estilo de aprendizaje, sino que muestran características de más de un estilo. Este hallazgo sugiere que los enfoques educativos personalizados deben considerar la flexibilidad y adaptabilidad de cada estudiante en lugar de encasillarlos en una única categoría de aprendizaje.

Por ejemplo, la salida de la red neuronal para un estudiante específico mostró los siguientes valores:

- Visual: 0.0071
- Auditivo: 0.9176
- Lectura/Escritura: 0.2154
- Kinestésico: 0.0018

Este resultado indica que, aunque el aprendizaje auditivo es predominante en este caso, también hay una contribución significativa del aprendizaje por lectura/escritura. Este hallazgo sugiere que los modelos tradicionales que clasifican a los estudiantes en un único tipo de aprendizaje pueden ser limitados y que una aproximación más flexible y basada en inteligencia artificial puede proporcionar una visión más precisa de las preferencias individuales.

Además, el análisis mostró que el 51.33% de los estudiantes acertaron en la identificación de su propio estilo de aprendizaje, lo que indica que existe un margen considerable de percepción subjetiva en la autoevaluación de los estudiantes. Esta diferencia resalta la importancia de complementar la autoevaluación con herramientas analíticas como las redes neuronales para obtener una visión más objetiva del proceso de aprendizaje.

Estos resultados sugieren que, si bien la identificación de un estilo predominante puede ser útil, los sistemas educativos deberían adoptar estrategias que permitan a los estudiantes desarrollar múltiples habilidades de aprendizaje en lugar de centrarse exclusivamente en un único enfoque. En este sentido, la aplicación de inteligencia artificial en la educación ofrece una oportunidad valiosa para comprender mejor las necesidades de los estudiantes y mejorar la personalización del proceso de enseñanza.

CONCLUSIONES

Los hallazgos de este estudio confirman que los estudiantes no se ajustan estrictamente a un único estilo de aprendizaje, sino que presentan combinaciones de diferentes categorías. El uso de inteligencia artificial permitió analizar con mayor precisión la diversidad de estilos de aprendizaje en la población estudiantil, evidenciando que los enfoques tradicionales de clasificación pueden ser limitados.

El primer objetivo del estudio fue identificar los estilos de aprendizaje mediante IA y compararlos con la autopercepción de los estudiantes. Se encontró que solo el 51.33% de los estudiantes identificaron correctamente su estilo de aprendizaje, lo que sugiere que la percepción subjetiva puede no ser un reflejo preciso de sus preferencias cognitivas reales.

En relación con el segundo objetivo, se evaluó una red neuronal optimizada con un algoritmo evolutivo para clasificar los estilos de aprendizaje. Los resultados obtenidos con la IA se contrastaron con los del modelo VARK tradicional, el cual asigna a los estudiantes a una única categoría de aprendizaje. Mientras que el método VARK clásico indicó que los estilos predominantes eran visual (46.1%) y kinestésico (38.9%), la IA reveló una mayor proporción de estudiantes kinestésicos (56.64%) y una menor presencia del estilo visual (27.43%). Esta diferencia sugiere que el modelo VARK, basado en la autoevaluación de los estudiantes, puede generar sesgos en la clasificación.

En cuanto al tercer objetivo, se determinó que la IA puede proporcionar una evaluación más objetiva y detallada de los estilos de aprendizaje en comparación con la autopercepción y con el modelo VARK convencional. Un hallazgo clave fue la identificación de perfiles mixtos, es decir, estudiantes que no pertenecen exclusivamente a un solo estilo de aprendizaje. La red neuronal mostró que un 28.32% de los estudiantes combinaban múltiples estilos, lo que sugiere que los modelos tradicionales, al forzar una clasificación única, pueden no captar la complejidad del aprendizaje real.

Respecto al cuarto objetivo, los resultados sugieren que los modelos de IA pueden mejorar la educación al permitir enfoques más flexibles y personalizados. En lugar de categorizar a los estudiantes de manera rígida, la IA permite identificar gradaciones y combinaciones entre estilos de aprendizaje, lo que podría ser aprovechado en estrategias educativas más adaptativas.

Además, este estudio subraya la importancia de replantear el uso del modelo VARK en entornos educativos. Si bien sigue siendo una herramienta útil, la integración de IA en la identificación de estilos de aprendizaje podría mejorar su precisión y reducir el impacto de la subjetividad en la autoevaluación.

Finalmente, es importante considerar las limitaciones del estudio, como el tamaño de la muestra y la necesidad de evaluar estos modelos en otros contextos académicos. Futuras investigaciones podrían enfocarse en la integración de estos sistemas en plataformas de educación digital para evaluar su impacto en la personalización del aprendizaje y en la efectividad de las estrategias pedagógicas basadas en IA.

BIBLIOGRAFÍA

Bilal Zorić, A., Miloloža, I., y Pejić Bach, M. (2022). *Neural networks for student performance in higher education: Preliminary bibliometric analysis*. En *Interdisciplinary Management Research XVIII (IMR 2022)* (pp. 762–781), Opatija, Croacia. (Actas registradas en EFZG).

Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT Press

Luckin, R., Holmes, W., Griffiths, M., y Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson. (PDF de UCL/Google).

Mitchell, M. (1998). *An introduction to genetic algorithms*. MIT Press.

- Sazli, M. (2006). A brief review of feedforward neural networks. *Communications, Faculty of Sciences, University of Ankara, Series A2-A3: Physical Sciences and Engineering*, 50(1), 11–17.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Stanley, K. O., Clune, J., Lehman, J., y Miikkulainen, R. (2019). Designing neural networks through neuroevolution. *Nature Machine Intelligence*, 1, 24–35. <https://doi.org/10.1038/s42256-018-0006-z>
- Woolf, B. P. (2010). *Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning*. Morgan Kaufmann.
- 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, 39. <https://doi.org/10.1186/s41239-019-0171-0>