

# Aplicación de Modelos de Inteligencia Artificial en Pruebas Estandarizadas para la Optimización del Rendimiento Académico en Educación Superior

## Application of Artificial Intelligence Models in Standardized Tests for Optimizing Academic Performance in Higher Education

Nathalia Orozco Morales<sup>1</sup>: Corporación Universitaria Minuto de Dios, Colombia.

[nathalia.orozco@uniminuto.edu](mailto:nathalia.orozco@uniminuto.edu)

Pável Andrei Osorio García: Corporación Universitaria Minuto de Dios, Colombia.

[pavel.osorio@uniminuto.edu.co](mailto:pavel.osorio@uniminuto.edu.co)

Fecha de Recepción: 8/05/2024

Fecha de Aceptación: 09/10/2024

Fecha de Publicación: 16/10/2024

### Cómo citar el artículo:

Orozco Morales, N. y Osorio García, P. A. (2024). Aplicación de Modelos de Inteligencia Artificial en Pruebas Estandarizadas para la Optimización del Rendimiento Académico en Educación Superior [Application of Artificial Intelligence Models in Standardized Tests for Optimizing Academic Performance in Higher Education]. *European Public & Social Innovation Review*, 9, 1-21. <https://doi.org/10.31637/epsir-2024-1605>

### Resumen:

**Introducción:** Aunque, la IA ha demostrado potencial para predecir resultados académicos, diseñar programas de aprendizaje personalizados y apoyar la orientación académica, se encuentran desafíos significativos como la necesidad de datos de alta calidad, problemas de interpretabilidad de algunos modelos y el riesgo de perpetuar sesgos existentes. El objetivo de la presente revisión sistemática es explorar el uso de la inteligencia artificial en el ámbito educativo, específicamente en el contexto de las pruebas estandarizadas. **Metodología:** Para ello, se lleva a cabo una revisión exhaustiva de la literatura científica siguiendo las directrices de la declaración PRISMA, con una muestra de 17 artículos publicados entre el 2019 y 2023 en revistas indexadas en Scopus. **Resultados:** Se encontró que los modelos predictivos más utilizados en los estudios fueron: Redes Neuronales Artificiales, Árboles de Decisión,

<sup>1</sup> Nathalia Orozco: Corporación Universitaria Minuto de Dios (Colombia).

Máquinas de Soporte Vectorial (SVM) y Random Forest, **Discusión:** identificando beneficios que incluyen la optimización del rendimiento académico, individualización del aprendizaje y mejora en la toma de decisiones educativas. **Conclusiones:** Se concluye que la IA tiene un gran potencial para mejorar la medición de la calidad educativa, pero es crucial abordar estas limitaciones y consideraciones éticas para garantizar su aplicación efectiva y responsable en el ámbito educativo.

**Palabras clave:** inteligencia artificial; rendimiento escolar; prueba de conocimiento; educación superior; aprendizaje; calidad de la educación; revisión; evaluación.

## Abstract:

**Introduction:** Although AI has shown potential to predict academic outcomes, design personalized learning programs, and support academic guidance, there are significant challenges such as the need for high-quality data, interpretability issues of some models, and the risk of perpetuating existing biases. The object of this systematic review explores the use of artificial intelligence in the educational field, specifically in the context of standardized tests.

**Methodology:** To achieve this, a comprehensive review of the scientific literature is conducted following the PRISMA statement guidelines, with a sample of 17 articles published between 2019 and 2023 in journals indexed in Scopus. **Results:** The most used predictive models in these studies were found to be: Artificial Neural Networks, Decision Trees, Support Vector Machines, and Random Forest, **Discussions:** identifying benefits that include optimizing academic performance, personalizing learning, and improving educational decision-making. **Conclusions:** It is concluded that AI has great potential to improve the measurement of educational quality, but it is crucial to address these limitations and ethical considerations to ensure its effective and responsible application in the educational field.

**Keywords:** artificial intelligence; academic performance; test; higher education; learning; quality of education; review; evaluation.

## 1. Introducción

### 1.1. Contexto y Justificación

La educación es ampliamente reconocida como uno de los pilares fundamentales en el desarrollo de las naciones, dado su papel crucial en la formación de habilidades necesarias para la vida laboral (Vanegas-Ayala *et al.*, 2021). En los últimos años, la inteligencia artificial (IA) ha emergido como una herramienta transformadora en diversos campos, incluida la educación. El auge de los datos masivos, los avances en tecnologías de almacenamiento y la creciente necesidad de obtener retroalimentación precisa han impulsado a las instituciones educativas a adoptar modelos predictivos basados en IA para optimizar su desempeño.

En el ámbito educativo, la implementación de la IA abarca desde el aprendizaje personalizado hasta la evaluación automatizada, adaptándose a las necesidades específicas de los estudiantes (Pastora Alejo y Fuentes Aparicio, 2020). Las competencias generales en la educación superior, según Restrepo Gómez (2013), engloban habilidades intelectuales que fomentan el "aprender a aprender", destrezas sociales para el trabajo en equipo, y competencias educativas (comunicativas, interpretativas, argumentativas y propositivas). En este contexto Delahoz-Dominguez *et al.* (2020) afirma que las pruebas estandarizadas juegan un papel fundamental en la medición de la calidad educativa, proporcionando parámetros objetivos para evaluar el rendimiento de estudiantes e instituciones, y permitiendo el análisis de factores externos que influyen en los resultados.

A pesar del creciente uso de la IA en educación, persiste una brecha significativa en la comprensión y aplicación de modelos específicos para analizar los resultados de pruebas estandarizadas y optimizar el rendimiento académico en la educación superior. La premisa central es que la IA tiene el potencial de revolucionar la educación superior al ofrecer un enfoque más personalizado y efectivo para el aprendizaje, beneficiando tanto a estudiantes como a instituciones, y mejorando la calidad educativa general (García Cruz *et al.* 2023).

Esta revisión sistemática se fundamenta en la necesidad de proporcionar a educadores, administradores y formuladores de políticas una visión integral basada en la evidencia sobre el potencial de la IA para mejorar los procesos educativos. Al examinar metódicamente la literatura existente, se busca identificar patrones, tendencias y mejores prácticas en la aplicación de modelos de IA a pruebas estandarizadas, con el objetivo de informar futuras investigaciones y aplicaciones prácticas en el campo.

Para garantizar el rigor y la transparencia de esta revisión, se ha seguido la declaración PRISMA (2020) para el reporte de revisiones sistemáticas (Page *et al.*, 2021). El proceso de selección de artículos, acorde con las recomendaciones de PRISMA, comenzó con la identificación de 40 artículos potencialmente relevantes. Tras una revisión detallada de los resúmenes, se excluyeron 20 artículos que, aunque mencionaban pruebas estandarizadas e inteligencia artificial, no utilizaban los datos de los resultados de las pruebas en los métodos o modelos de IA. De los 20 restantes, uno fue excluido por no cumplir con los criterios de idioma, y dos más fueron descartados por requerir pago para su acceso.

En el contexto del conocimiento existente, esta revisión se enfoca en las técnicas de IA más utilizadas en el análisis de pruebas estandarizadas y la optimización del rendimiento académico. Entre estas técnicas destacan:

- Árboles de decisión: Valorados por su transparencia y facilidad de interpretación, permiten visualizar claramente las reglas que impulsan una clasificación o predicción (Das y Cakmak, 2018; Bonaccorso, 2018).
- Máquinas de vectores de soporte (SVM): Apreciadas por su capacidad para manejar conjuntos de datos de alta dimensión y su eficacia en problemas de clasificación complejos (Bonaccorso, 2018).
- Bosques aleatorios: Como técnica de conjunto, ofrecen una robustez adicional al combinar múltiples árboles de decisión, mejorando la precisión de las predicciones (Bonaccorso, 2018).
- Regresión logística: Según Bonaccorso, (2018 p.145) es un método de clasificación basado en la probabilidad de que una muestra pertenezca a una clase.
- Análisis de Componentes Principales (PCA): un método para reducir la dimensionalidad de los datos seleccionando un subconjunto de características que contienen la mayor cantidad de varianza total. Este enfoque permite des-correlacionar las características y reducir la dimensionalidad sin una pérdida drástica de precisión. (Bonaccorso, 2018)
- Redes neuronales: se usan para modelar relaciones complejas y no lineales en los datos, lo que les permite sobresalir en tareas que los métodos lineales encuentran difíciles o

imposibles. Debido a que pueden aproximar cualquier función continua con precisión arbitraria, las redes neuronales se consideran aproximadores de funciones universales. (Bonaccorso, 2018)

Esta revisión bibliográfica no solo busca sintetizar el conocimiento existente sobre las técnicas de IA más utilizadas en el análisis de pruebas estandarizadas, sino también identificar brechas en la investigación actual y proponer direcciones futuras para la aplicación de la IA en la optimización del rendimiento académico en la educación superior. Al hacerlo, esta revisión contribuye al cuerpo de conocimiento existente y proporciona una base sólida para futuras investigaciones y aplicaciones prácticas en este campo en rápida evolución.

## 1.2. *Pregunta de Investigación*

Dada la creciente influencia de la IA en la educación, esta revisión bibliográfica tiene como objetivo responder a la siguiente pregunta: ¿Cuáles son las principales investigaciones que han aplicado IA para el análisis de datos de exámenes estandarizados en la medición de la calidad educativa, según publicaciones indexadas en Scopus entre 2019 y 2023?

## 1.3. *Objetivos del Estudio*

- Identificar los modelos de inteligencia artificial utilizados en las pruebas estandarizadas a nivel mundial. Comprendiendo como pruebas estandarizadas los exámenes diseñados para evaluar el rendimiento académico de los estudiantes de manera uniforme y objetiva. (Soto-Acevedo *et al.*, 2023)
- Analizar el comportamiento y la forma de evaluación de estos modelos. Estos modelos se pueden utilizar para predecir el rendimiento de los estudiantes y para clasificar los resultados de las pruebas (Sanabria James *et al.* 2020).
- Destacar las ventajas de utilizar estos algoritmos para la optimización del rendimiento académico en la educación superior. Algunas ventajas son la capacidad de identificar a los estudiantes en riesgo, proporcionar retroalimentación personalizada y mejorar la eficiencia de los procesos de evaluación (Rudd *et al.*, 2021).

## 2. Materiales

### 2.1. *Fuentes de Información*

Scopus es una base de datos bibliográfica extensa que contiene diversas disciplinas, incluyendo ciencias, tecnología, medicina, ciencias sociales y artes y humanidades (Elsevier, n.d.). Contiene más de 85 millones de registros de revistas científicas, libros, actas de conferencias y sitios web de alta calidad. Su amplio alcance la convierte en un instrumento valioso para la búsqueda de información científica.

### 2.2. *Justificación para la elección de Scopus*

- Cobertura: Su amplio alcance, que abarca una gran cantidad de publicaciones y disciplinas, permite encontrar una amplia gama de investigaciones relevantes para la consulta.
- Métricas: Scopus proporciona métricas como el índice h y el factor de impacto de las revistas, que permiten evaluar la calidad e impacto de la investigación.
- Fiabilidad: Scopus es reconocido por su fiabilidad y la alta calidad de la información, sometida a rigurosos controles de calidad.

- Herramientas de búsqueda: Scopus ofrece herramientas de búsqueda avanzadas que facilitan la búsqueda precisa de información relevante.

### 2.3. *Criterios de selección*

- **Período de tiempo:** 2019-2023.
- **Tipo de publicaciones:** Artículos de revistas científicas, actas de congresos y simposios y tesis doctorales indexadas en Scopus.
- **Criterios de inclusión:**
  - Artículos publicados en inglés o español.
  - Estudios que usen técnicas de IA con datos de exámenes estandarizados.
  - Investigaciones sobre educación superior.
  - Artículos disponibles de forma gratuita.
  - Publicaciones indexadas en Scopus.
  - Estudios empíricos con resultados originales o revisiones teóricas que sintetizen hallazgos.

### 2.4. *Criterios de selección*

- Artículos en idiomas diferentes al inglés o al español.
- Estudios que no utilicen IA o datos de exámenes estandarizados.
- Investigaciones no relacionadas con la educación superior.
- Artículos que requieren pago para su acceso.
- Publicaciones no indexadas en Scopus.
- Estudios que no presenten resultados originales o que no sintetizen hallazgos previos.

## 3. Métodos

### 3.1. *Estrategia de Búsqueda Detallada*

PICO: Definición de la Pregunta de Investigación

- **Población (P):** Investigaciones sobre análisis de datos de exámenes estandarizados en el contexto de la medición de la calidad educativa.
- **Intervención (I):** Aplicaciones de Inteligencia Artificial (IA).
- **Comparación (C):** Metodologías de evaluación en el análisis de datos educativos.
- **Resultados (O):** Identificación de las principales investigaciones y sus hallazgos en la aplicación de IA para el análisis de datos de exámenes estandarizados en la medición de la calidad educativa.

Desarrollo del Protocolo (Criterios de Inclusión y Exclusión)

- **Idioma:** inglés, dada la naturaleza internacional de la investigación en IA y la calidad educativa. Español, dado que la investigación busca impactar el entorno local y es posible que si existe alguna investigación pueda esta estar en idioma nativo.
- **Tipo de publicación:** Artículos de revistas científicas, actas de congresos y simposios, y tesis doctorales indexadas en Scopus. Se priorizarán artículos de revistas por su rigor científico.
- **Rango de Fechas:** Publicaciones entre 2019 y 2023.

- **Exclusión:** Artículos que no aborden directamente la aplicación de IA en el análisis de datos de exámenes estandarizados para la medición de la calidad educativa.
- **Búsqueda Bibliográfica**
- **Bases de Datos:** Scopus.

Para la revisión sistemática, desarrollamos una estrategia de búsqueda integral que abarcó tres áreas principales: inteligencia artificial, pruebas estandarizadas y educación superior. En el campo de la inteligencia artificial, se incluyeron términos como "inteligencia artificial", "aprendizaje automático", "aprendizaje profundo" y "redes neuronales". Para las pruebas estandarizadas, utilizando descriptores como "pruebas de rendimiento", "pruebas de competencia", "pruebas de aptitud", "exámenes de ingreso a la universidad" y "pruebas de colocación". En cuanto a la educación superior, se emplearon términos como "educación superior", "universidades", "educación postsecundaria" y "educación terciaria". Dentro de cada área, se conectaron los términos con el operador OR para capturar la diversidad de la terminología.

Para asegurar que los estudios recuperados abordaran la intersección de estas tres áreas, se utilizó el operador AND entre los grupos de términos. Además, se aplicó un filtro temporal para incluir solo estudios publicados entre 2019 y 2023, utilizando los operadores > y < con la función PUBYEAR. Para garantizar la relevancia de los resultados, limitamos la búsqueda a los campos de título, resumen y palabras clave de los artículos mediante el prefijo TITLE-ABS-KEY. Esta estrategia permitió identificar estudios que exploran específicamente la aplicación de técnicas de inteligencia artificial en pruebas estandarizadas dentro del contexto de la educación superior, proporcionando una base sólida para la revisión.

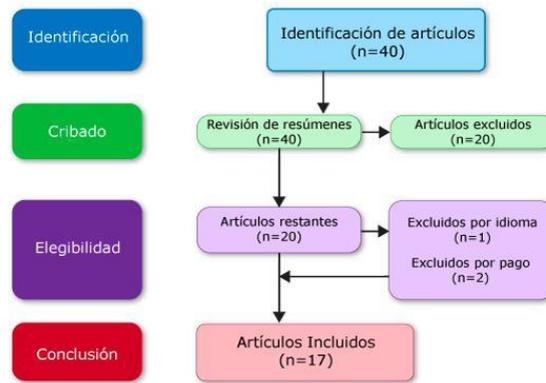
### 3.2. Selección de estudios

La aplicación de la estrategia de búsqueda en la base de datos Scopus arrojó inicialmente un total de 40 artículos potencialmente relevantes. Estos artículos constituyeron el conjunto inicial para nuestro proceso de revisión y selección.

Para evaluar la pertinencia y calidad de estos 40 artículos, se implementó un riguroso protocolo de revisión basado en el método PRISMA. Dos revisores independientes examinaron los resúmenes de cada artículo utilizando un formulario estandarizado, que incorporaba nuestros criterios predefinidos de inclusión y exclusión. Este enfoque aseguró una evaluación consistente y objetiva de cada estudio. En los casos donde surgieron discrepancias entre los revisores, se llevaron a cabo discusiones detalladas para alcanzar un consenso.

### Figura 1.

*Diagrama de flujo PRISMA 2020*



**Fuente:** Elaboración propia (2024).

### 3.3. *Extracción de datos*

Los datos relevantes de los estudios seleccionados se extraen utilizando un formulario estandarizado que incluye:

- Título
- Autor
- Edición
- Fecha
- Palabras Clave
- Descripción
- Fuentes
- Contenido
- Metodología
- Conclusiones
- Autor del RAE

### 3.4. *Evaluación de Riesgo de Sesgos*

Para evaluar el riesgo de sesgo, se investigaron diversas herramientas. Entre las herramientas consideradas se incluyen:

- AMSTAR 2: Esta herramienta se utiliza para evaluar “la calidad de las revisiones sistemáticas de estudios aleatorizados y no aleatorizados”. Es adecuada para investigaciones en inteligencia artificial y educación, pero no está específicamente diseñada para modelos de predicción. AMSTAR 2 se enfoca en aspectos metodológicos como la transparencia y el rigor de la revisión sistemática, proporcionando una evaluación crítica de la confianza en los resultados obtenidos (Shea et al., 2017).
- QUADAS-2: Esta herramienta evalúa el riesgo de sesgo y la aplicabilidad de los estudios de precisión diagnóstica. Es útil para revisiones que incluyen estudios de precisión de modelos de IA, aunque no está específicamente diseñada para modelos de predicción educativa. QUADAS-2 se destaca por su enfoque en estudios de precisión diagnóstica y es ampliamente utilizada en revisiones sistemáticas de pruebas diagnósticas (Whiting et al., 2011).
- ROBINS-I: Adecuada para evaluar el riesgo de sesgo en estudios no aleatorizados de intervenciones, lo cual es relevante para muchos estudios de IA en educación. Sin embargo, no está enfocada en modelos de predicción. ROBINS-I es especialmente útil para estudios observacionales y proporciona una evaluación detallada del riesgo de sesgo en varios dominios, ayudando a identificar posibles fuentes de confusión y sesgo (Sterne et al., 2016).
- PROBAST: Diseñada específicamente para evaluar estudios de desarrollo y validación de modelos de predicción. Dado que esta revisión se centra en modelos de inteligencia artificial, PROBAST es la herramienta más adecuada. PROBAST evalúa tanto el riesgo de sesgo como la aplicabilidad de los estudios de predicción, proporcionando una guía completa para la evaluación de modelos predictivos en diversas áreas, incluyendo la medicina y la educación (Wolff et al., 2019).

Se seleccionó la herramienta PROBAST como la más adecuada debido a su enfoque específico en evaluar estudios de modelos de predicción. Como se explicó anteriormente, dos revisores

independientes evaluaron el riesgo de sesgo, discutieron las discrepancias y llegaron a un consenso. El análisis de sesgo se realizó en cuatro dominios: Participantes, Predictores, Resultados y Análisis, con una ponderación final del riesgo de sesgo para cada artículo (Wolff et al., 2019). A continuación, se presenta la tabla 1 resultante del análisis de riesgo para los 17 artículos seleccionados para la revisión:

**Tabla 1.**

*Análisis de riesgo*

<b>Estudio</b>	<b>Participantes</b>	<b>Predictores</b>	<b>Resultados</b>	<b>Análisis</b>	<b>Riesgo Global</b>
<b>Soto-Acevedo et al. (2023)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Thomas et al. (2024)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Qahmash et al. (2023)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Guevara-Flores et al. (2023)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Song y Ke (2023)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Alhazmi y Sheneamer (2023)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Islam Suvon et al. (2022)</b>	Riesgo poco claro	Bajo riesgo	Bajo riesgo	Bajo riesgo	Riesgo poco claro
<b>Neda &amp; Gago-Masague (2022)</b>	Riesgo poco claro	Bajo riesgo	Bajo riesgo	Bajo riesgo	Riesgo poco claro
<b>Assiri et al. (2022)</b>	Riesgo poco claro	Bajo riesgo	Bajo riesgo	Bajo riesgo	Riesgo poco claro
<b>Cunningham et al., 2021</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Gao et al. (2021)</b>	Riesgo poco claro	Bajo riesgo	Bajo riesgo	Bajo riesgo	Riesgo poco claro
<b>Fateh Allah (2020)</b>	Riesgo poco claro	Bajo riesgo	Bajo riesgo	Bajo riesgo	Riesgo poco claro
<b>Delahoz-Dominguez et al. (2020)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Mengash (2020)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Das y Rodriguez-Marek (2019)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>Chen et al. (2022)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo
<b>de Castro Rodrigues et al. (2019)</b>	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo	Bajo riesgo

**Fuente:** Elaboración propia (2024)

### 3.5. *Conclusión con respecto al sesgo*

Tras realizar el análisis PROBAST de los 17 artículos seleccionados para esta revisión, se pueden extraer las siguientes conclusiones:

#### 3.5.1. *Distribución del riesgo:*

- 12 artículos (70.6%) presentan un bajo riesgo global de sesgo.
- 5 artículos (29.4%) muestran un riesgo poco claro.
- Ningún artículo fue clasificado con alto riesgo de sesgo.

#### **Artículos con riesgo poco claro:**

Los siguientes estudios fueron clasificados con riesgo poco claro:

- "Masters and Doctor of Philosophy Admission Prediction of Bangladeshi Students"
- "Feasibility of Machine Learning Support for Holistic Review of Undergraduate Applications"
- "Improve the Accuracy of Students Admission at Universities Using Machine Learning Techniques"
- "Classification Decision Tree Algorithm in Predicting Students' Course Preference"
- "Using Machine Learning to Support Students' Academic Decisions"

#### **Análisis de dominios:**

El dominio "Participantes" fue el único que presentó riesgo poco claro en los 5 artículos mencionados. Los dominios de "Predictores", "Resultados" y "Análisis" fueron consistentemente evaluados como de bajo riesgo en todos los estudios.

#### **Riesgo poco claro en el dominio de "Participantes":**

En el estudio "Masters and Doctor of Philosophy Admission Prediction of Bangladeshi Students," la representatividad de la muestra no fue claramente detallada, lo que podría introducir sesgos en la generalización de los resultados (Suvon et al., 2022).

El estudio "Feasibility of Machine Learning Support for Holistic Review of Undergraduate Applications" no proporcionó suficiente información sobre cómo se seleccionaron los participantes, dejando dudas sobre la representatividad de la muestra (Martinez Neda y Gago-Masague, 2022).

En "Improve the Accuracy of Students Admission at Universities Using Machine Learning Techniques" hubo falta de claridad sobre la composición de la muestra estudiantil y sus características demográficas (Assiri et al., 2022)

"Classification Decision Tree Algorithm in Predicting Students' Course Preference" también careció de una descripción detallada de los participantes, lo que podría afectar la aplicabilidad de los hallazgos (Gao et al., 2021).

El estudio "Using Machine Learning to Support Students' Academic Decisions" no especificó adecuadamente los criterios de inclusión y exclusión de los participantes, resultando en una posible falta de representatividad (Fateh Allah, 2020).

### 3.5.2. *Implicaciones:*

La mayoría de los estudios incluidos (70.6%) presentan un bajo riesgo de sesgo, lo que sugiere que sus hallazgos son generalmente confiables y válidos. Esto proporciona una base sólida para las conclusiones de nuestra revisión sistemática. Sin embargo, el 29.4% de los estudios muestran un riesgo poco claro, principalmente debido a la falta de información detallada sobre la representatividad de los participantes. Esto introduce cierta incertidumbre en la generalización de los resultados de estos estudios específicos.

### 3.5.3. *Limitaciones y consideraciones*

La falta de claridad en el dominio de "Participantes" en algunos estudios sugiere la necesidad de una mayor transparencia en la descripción de las poblaciones de estudio en futuras investigaciones.

A pesar del riesgo poco claro en algunos estudios, es importante notar que ningún dominio fue clasificado como de alto riesgo, lo que refuerza la calidad general de la evidencia recopilada.

Aunque la mayoría de los estudios presentan un bajo riesgo de sesgo, la presencia de un riesgo poco claro, casi un tercio de los artículos subraya la importancia de una interpretación cuidadosa de los resultados y la necesidad de mayor rigurosidad en la descripción metodológica en futuras investigaciones en este campo.

## 3.6. *Síntesis de la evidencia*

Los hallazgos de los estudios seleccionados se sintetizarán de manera narrativa, describiendo las principales investigaciones, los estudios en el contexto local, los métodos de IA utilizados, los resultados y las conclusiones.

## 4. Resultados y discusión

### 4.1. *Identificación de modelos de IA*

En la revisión de la literatura, se identificaron varios modelos de inteligencia artificial (IA) utilizados para diferentes propósitos en el análisis del rendimiento académico en pruebas estandarizadas. Los principales modelos incluyen proyectos que se centran solo en admisiones para la educación superior, comparativas entre las pruebas de admisión y los primeros resultados académicos en las universidades y el análisis de resultados de las pruebas de estado a nivel de pregrado, a continuación, se incluyen las diversas técnicas implementadas de forma supervisada:

- **Redes Neuronales Artificiales (ANN):** Utilizadas principalmente para predecir el rendimiento académico y evaluar competencias específicas, las ANN han mostrado una alta precisión en la identificación de patrones complejos en los datos educativos, en algunos casos inclusive se aplican este tipo de modelos para hallar predicciones que aportan información en el mismo periodo académico o en futuros cursos (Fateh Allah, 2020).

En Cunningham et al., (2021) utilizaron ANN para predecir la retención de estudiantes, encontrando una precisión significativa en sus predicciones. El modelo se empleó para

identificar los factores que influyen en la retención estudiantil y proporcionar intervenciones tempranas. Mientras que Thomas *et al.*, (2024) empleó varias técnicas de Machine Learning para identificar el riesgo de abandono o deserción de estudiantes de ingeniería de la Universidad de Louisville que ingresaron sobre el 2018 y 2019, se encontró en este estudio que la red neuronal es poco precisa, a pesar de que se utilizaron varios métodos de optimización. Otros métodos de Castro Rodrigues *et al.* (2019) utilizan técnicas de Data Mining que incluyen redes neuronales con el fin de analizar los perfiles que ingresan a carreras universitarias.

- **Árboles de Decisión (DT):** Empleados para clasificar y predecir preferencias académicas y resultados de admisión, los DT son útiles por su interpretabilidad y capacidad de manejar datos numéricos y categóricos, por ejemplo, si el árbol de decisión se utiliza de forma categórica puede ser programado para arrojar respuestas de tipo binario (su nodo principal se divide en dos) proporcionando la “mejor división para un criterio establecido” (Delahoz-Dominguez *et al.*, 2020). Song y Ke (2023) emplearon árboles de decisión para predecir las preferencias de curso de los estudiantes, mostrando una alta precisión en la clasificación. Este modelo se utilizó para asistir a los consejeros académicos en la orientación de los estudiantes hacia cursos alineados con sus intereses y habilidades. Delahoz-Dominguez *et al.* (2020) dispone de esta técnica para evaluar si el resultado de las pruebas estandarizadas tipo Saber PRO están correlacionadas con la acreditación institucional, para este caso se demuestra que la variable de comunicación escrita es esencial para clasificar y posicionar a las universidades en alta calidad. Ahora, otro tipo de estudios realizan este tipo de técnicas para “analizar los datos de ingreso a las universidades y predecir la clasificación a los programas” (Gao *et al.*, 2021).
- **Máquinas de Soporte Vectorial (SVM):** Utilizadas para predecir el rendimiento académico y apoyar decisiones educativas, las SVM son efectivas para manejar datos complejos y no lineales. Esta técnica traza un hiperplano que separa las clases, buscando maximizar sus márgenes con el fin de encontrar la mejor posición para la separación adecuada de las clases según Mengash (2020). Martínez Neda y Gago-Masague (2022) utilizaron SVM para apoyar las decisiones académicas de los estudiantes, destacando su capacidad para manejar datos complejos y no lineales. El SVM se aplicó para predecir el rendimiento académico y proporcionar recomendaciones personalizadas para mejorar el desempeño. Mientras que Alhazmi y Sheneamer (2023) lo utilizan para comparar los puntajes de admisión con las calificaciones de los cursos de primer nivel, evidenciando que las técnicas de machine learning pueden ser útiles para mitigar el riesgo de deserción de estudiantes en etapas tempranas.
- **Random Forest:** Este modelo se ha utilizado para predecir resultados en exámenes estandarizados y mejorar estrategias de enseñanza, mostrando una alta precisión debido a su capacidad de manejar grandes volúmenes de datos y reducir el sobreajuste, Random Forest utiliza los árboles de decisión para crear múltiples respuestas y luego clasifica basándose en la respuesta más común. El modelo considera dos parámetros claves para programar su respuesta: el número de árboles y el número de variables utilizadas para dividir los nodos (Soto-Acevedo *et al.*, 2023).
- **Song, Z. y Ke, K. (2023) utilizaron Random Forest para predecir los resultados del examen CET-4,** demostrando una mejora en la precisión de las predicciones en comparación con otros modelos. Este enfoque se usó para identificar las áreas en las que los estudiantes necesitaban más apoyo y mejorar las estrategias de enseñanza.

Es importante mencionar que varios artículos evidencian el uso de diferentes modelos para realizar comparativas en diversas variables. Por ejemplo, Das y Rodríguez-Marek (2019), Assiri *et al.* (2022) utilizan estos modelos para identificar patrones que pueden influir en las pruebas estandarizadas utilizadas en los procesos de admisión y el desarrollo en el aula. Estos estudios emplean múltiples recursos que permiten intuir resultados futuros en las carreras universitarias de los estudiantes, así como el riesgo de deserción. Así mismo, se evidenciaron técnicas no supervisadas al iniciar los estudios para la identificación de variables que ingresan a los modelos supervisados.

Además, los artículos analizan cómo diversos factores impactan en el desempeño académico y profesional de los estudiantes. Entre estos factores se incluyen los antecedentes estudiantiles, la economía, el tiempo disponible, el presupuesto, los aspectos psicológicos, el género, las habilidades individuales, la situación del mercado laboral y la influencia de familiares y amigos. Al considerar estos elementos, los modelos proporcionan una visión integral de las posibles dificultades y ventajas que los estudiantes pueden enfrentar a lo largo de su trayectoria académica y profesional.

## 4.2. Comportamiento y evaluación

### 4.2.1. Técnicas Utilizadas y Características Identificadas en los Resultados

#### Métodos de Clasificación y Predicción

- **Árboles de Decisión:** Utilizados en varios estudios, incluyendo el de Assiri *et al.*, 2022, donde se aplicaron para mejorar la precisión en la admisión de estudiantes. Este modelo ayudó a las universidades a identificar a los candidatos más prometedores basándose en múltiples criterios de admisión.
- **Redes Neuronales:** Guevara-Flores *et al.* (2023) utilizaron ANN para evaluar la competencia en inglés, logrando una alta precisión en la clasificación de niveles de competencia. El modelo permitió identificar las debilidades específicas de los estudiantes y diseñar programas de aprendizaje personalizados.

#### Enfoques de Preprocesamiento de Datos

- **Normalización y Selección de Características:** Alhazmi, E., y Sheneamer, A. (2023) aplicaron técnicas de normalización y selección de características para mejorar la precisión de las predicciones de rendimiento estudiantil. Estas técnicas permitieron reducir el ruido en los datos y enfocarse en las variables más relevantes para el éxito académico.

### 4.2.2. Comparación de Metodologías de Evaluación

#### Métricas de Evaluación:

- **Precisión y AUC:** Soto-Acevedo *et al.*, 2023 y Das y Rodríguez-Marek (2019) utilizaron métricas de precisión y AUC para evaluar el rendimiento de los modelos, mostrando altos niveles de exactitud en sus predicciones. Estas métricas permitieron comparar la efectividad de diferentes modelos y seleccionar el más adecuado para cada contexto educativo.

## Enfoques de Validación:

- **Validación Cruzada k-Fold:** Martínez Neda, B. y Gago-Masague, S. (2022) emplearon validación cruzada k-fold para asegurar la robustez de los modelos, demostrando la efectividad de este enfoque para evitar el sobreajuste. La validación cruzada ayudó a garantizar que los modelos mantenían su precisión en diferentes subconjuntos de datos.

### 4.3. *Ventajas de los Algoritmos de IA*

#### 4.3.1. *Discusión sobre las Ventajas de Utilizar IA en la Educación Contemporánea*

La revisión de los artículos seleccionados revela un consenso general sobre las ventajas significativas que ofrece la Inteligencia Artificial (IA) en la educación contemporánea. Sin embargo, es importante notar que estos beneficios varían en su aplicación y eficacia según el contexto específico de cada estudio.

#### 4.3.2. *Contexto local*

Los procesos que llaman la atención por su acercamiento local son: El artículo de Soto-Acevedo et al. (2023) que analiza el desempeño de los estudiantes con las pruebas Saber PRO del año 2018 y las pruebas estandarizadas Saber 11 presentadas por los mismos estudiantes en años anteriores, tomando una muestra de 12410 evaluaciones que arrojan datos de las variables socioeconómicas, la universidad y el programa escogido. Así, se comparan varios elementos de evaluación para visualizar qué modelo de entrenamiento se acomoda mejor a los datos en cuanto a sus resultados numéricos, pero el modelo lineal generalizado (GLM) presenta mejores resultados, superando a otros modelos como KNN, Random Forest y Support Vector Machine, por lo que esta investigación permite identificar los resultados de las pruebas Saber PRO e identificar estrategias desde el inicio de los cursos en pregrado. El estudio realizado por Delahoz-Dominguez *et al.* (2020) analiza la relación entre las acreditaciones de calidad en programas de ingeniería industrial y los resultados en las pruebas estandarizadas de educación superior en Colombia. Utilizando técnicas de aprendizaje automático (Árboles de Decisión, Random Forest y Regresión Logística), se buscó identificar patrones y correlaciones que pudieran influir en el desempeño académico. Los hallazgos evidenciaron la conexión entre la calidad universitaria y el rendimiento académico, resaltando la relevancia de contar con acreditaciones de calidad para mejorar la percepción estudiantil y fomentar el mejoramiento continuo en las instituciones educativas.

#### 4.3.3. *Optimización del Rendimiento Académico*

Varios estudios coinciden en que la IA puede optimizar significativamente el rendimiento académico, aunque a través de diferentes enfoques:

- Mengash, H. A. (2020) demostraron cómo los algoritmos de minería de datos pueden mejorar el proceso de admisión universitaria. Su enfoque se centró en la selección más precisa de candidatos, lo que resultó en un uso más eficiente de los recursos universitarios y en mejores resultados académicos.
- En contraste, Soto-Acevedo et al. (2023) utilizaron técnicas de Machine Learning para predecir los resultados en pruebas estandarizadas como las Saber PRO en Colombia. Su estudio mostró que es posible identificar estrategias de mejora desde el inicio de los cursos de pregrado, ofreciendo una perspectiva a más largo plazo sobre la optimización del rendimiento.

- Por otro lado, Thomas *et al.* (2023) se enfocaron en la predicción temprana del riesgo de deserción en estudiantes de ingeniería. Aunque encontraron que las redes neuronales eran menos precisas que otros métodos, su estudio subraya la importancia de seleccionar el modelo adecuado para cada contexto educativo.

Estos estudios demuestran que la IA puede abordar la optimización del rendimiento académico desde múltiples ángulos, desde la admisión hasta la retención y el desempeño en pruebas estandarizadas.

#### 4.3.4. Personalización del Aprendizaje

La capacidad de la IA para personalizar el aprendizaje es una ventaja destacada por varios investigadores:

- Guevara-Flores *et al.* (2023) utilizaron Redes Neuronales Artificiales (ANN) para evaluar la competencia en inglés, logrando no solo una alta precisión en la clasificación de niveles, sino también la identificación de debilidades específicas de los estudiantes. Esto permitió diseñar programas de aprendizaje personalizados.
- En comparación, Martínez Neda y Gago-Masague (2022) emplearon Máquinas de Soporte Vectorial (SVM) para apoyar las decisiones académicas de los estudiantes. Su enfoque se centró en proporcionar recomendaciones personalizadas para mejorar el desempeño, demostrando la versatilidad de la IA en la adaptación a las necesidades individuales de los estudiantes.

Estos estudios subrayan cómo diferentes técnicas de IA pueden contribuir a la personalización del aprendizaje, adaptándose a las necesidades específicas de cada estudiante.

#### 4.3.5. Mejora en la Toma de Decisiones Educativas

La IA ha demostrado ser una herramienta valiosa para mejorar la toma de decisiones en diversos aspectos de la educación:

- Song y Ke (2023) utilizaron árboles de decisión para predecir las preferencias de curso de los estudiantes. Su estudio mostró cómo la IA puede asistir a los consejeros académicos en la orientación de los estudiantes hacia cursos alineados con sus intereses y habilidades.
- En contraste, Delahoz-Domínguez *et al.* (2020) aplicaron técnicas de IA para evaluar la relación entre las acreditaciones de calidad en programas de ingeniería industrial y los resultados en pruebas estandarizadas. Este enfoque demuestra cómo la IA puede informar decisiones a nivel institucional y de política educativa.
- Alhazmi y Sheneamer (2023) utilizaron SVM para comparar los puntajes de admisión con las calificaciones de los cursos de primer nivel, demostrando la utilidad de la IA para mitigar el riesgo de deserción en etapas tempranas.

Estos estudios ilustran cómo la IA puede apoyar la toma de decisiones en múltiples niveles del sistema educativo, desde la orientación individual de los estudiantes hasta la evaluación de programas académicos.

#### 4.3.6. Análisis Crítico de los Beneficios y Limitaciones

A pesar de los numerosos beneficios identificados, es crucial mantener una perspectiva crítica sobre la aplicación de la IA en la educación:

##### **Beneficios:**

- Análisis Profundo de Datos: Soto-Acevedo *et al.*, (2023) demostraron cómo la IA permite un análisis más profundo y preciso de los datos educativos, mejorando la correlación entre los requisitos de admisión y el rendimiento académico.
- Identificación de Patrones Ocultos: Varios estudios, incluyendo el de Song y Ke (2023), mostraron cómo la IA puede identificar patrones en los datos que no son evidentes con métodos tradicionales, lo que lleva a *insights* valiosos para mejorar las estrategias de enseñanza.

##### **Limitaciones:**

- Necesidad de Datos de Alta Calidad: Pentel y Kaiva (2020) destacaron la necesidad de grandes volúmenes de datos de alta calidad para que los modelos de IA sean efectivos, lo cual puede ser un desafío en algunos contextos educativos.
- Interpretabilidad: Algunos modelos de IA, especialmente las redes neuronales complejas, pueden carecer de interpretabilidad, lo que dificulta su aplicación práctica en entornos educativos donde la transparencia es crucial.
- Sesgos Potenciales: Varios investigadores advierten sobre el riesgo de perpetuar sesgos existentes si los modelos de IA se basan únicamente en datos históricos sin considerar factores contextuales y personales de los estudiantes.

En conclusión, mientras que la IA ofrece ventajas significativas en la optimización del rendimiento académico, la personalización del aprendizaje y la mejora de la toma de decisiones educativas es crucial abordar sus limitaciones y desafíos éticos para maximizar su potencial en la educación contemporánea. La comparación entre los diferentes estudios revela la importancia de seleccionar cuidadosamente los modelos y técnicas de IA según el contexto específico y los objetivos educativos.

## 5. Conclusiones

La revisión sistemática sobre la aplicación de modelos de inteligencia artificial (IA) en la educación ha arrojado hallazgos significativos, particularmente en el ámbito de las pruebas estandarizadas y la predicción del rendimiento académico. Los modelos de IA, como las redes neuronales artificiales y las máquinas de soporte vectorial, han demostrado ser altamente eficaces en la predicción del rendimiento de los estudiantes y en el análisis de los factores que contribuyen al éxito académico (Pentel y Kaiva, 2020; Soto-Acevedo *et al.*, 2023). Estas herramientas han permitido identificar patrones complejos en los datos educativos, ofreciendo *insights* valiosos para mejorar las estrategias de enseñanza y orientación académica. Además, técnicas de aprendizaje automático como los árboles de decisión y los algoritmos de Random Forest han sido utilizadas con éxito para clasificar y predecir preferencias académicas y resultados de exámenes estandarizados (Wang y Liu, 2020; Li *et al.*, 2019).

La aplicación de la IA en la evaluación de la calidad de la educación superior ha sido otro aspecto destacado, permitiendo analizar la correlación entre los requisitos de admisión y el rendimiento académico posterior (Soto-Acevedo *et al.*, 2023). La minería de datos, por su parte,

ha demostrado ser una herramienta poderosa para optimizar los procesos de admisión universitaria y apoyar la toma de decisiones académicas, proporcionando recomendaciones personalizadas para mejorar el desempeño estudiantil (Mengash, 2020; Das y Rodríguez-Marek, 2019). Estos avances tienen implicaciones significativas para la práctica y la política educativa, ya que permiten mejorar los procesos de admisión, hacerlos más precisos y eficientes, y ofrecer un apoyo más personalizado a los estudiantes en la toma de decisiones académicas.

La capacidad de la IA para identificar la influencia de factores socioeconómicos en el rendimiento académico abre nuevas posibilidades para intervenciones más específicas y efectivas (Pentel y Kaiva, 2020). Esto, junto con la evaluación continua de la calidad educativa que permite la IA, puede ayudar a las instituciones a identificar áreas de mejora y a implementar estrategias más efectivas. Además, la identificación de áreas de debilidad en la población estudiantil, especialmente en relación con las pruebas estandarizadas, proporciona información valiosa para los responsables de políticas públicas, permitiéndoles tomar medidas para mejorar estos aspectos.

Sin embargo, es importante reconocer las limitaciones de este estudio y considerar recomendaciones para futuras investigaciones e implementaciones. Se sugiere ampliar el alcance de los modelos de IA, investigando su aplicación en diversos contextos educativos y niveles de enseñanza. La integración de factores psicológicos y sociales en los modelos de predicción podría proporcionar una visión más holística del rendimiento académico. Además, ampliar la base de búsqueda más allá de Scopus podría enriquecer la diversidad de estudios y enfoques analizados.

Para una implementación efectiva de estos modelos en sistemas educativos, es crucial invertir en la capacitación y desarrollo profesional de educadores y administradores, así como en el desarrollo y mantenimiento de la infraestructura tecnológica necesaria. También es importante abordar las consideraciones éticas y los posibles sesgos que pueden surgir del uso de modelos de IA basados en datos históricos, asegurando que se tengan en cuenta las circunstancias personales de los estudiantes.

Mirando hacia el futuro, se recomienda realizar estudios comparativos entre enfoques tradicionales y aquellos basados en IA para evaluar sus respectivas eficacias y limitaciones en el contexto educativo. Esta línea de investigación podría proporcionar una comprensión más profunda de cómo integrar de manera óptima la IA en los sistemas educativos, maximizando sus beneficios mientras se mitigan sus potenciales desventajas. En última instancia, el objetivo es utilizar la IA como una herramienta para mejorar la calidad de la educación, personalizar el aprendizaje y proporcionar oportunidades educativas más equitativas para todos los estudiantes.

## 6. Referencias

- Alhazmi, E. y Sheneamer, A. (2023). Early predicting of students performance in higher education. *IEEE Access*, 11, 27579-27589. <https://doi.org/10.1109/ACCESS.2023.3250702>
- Assiri, B., Bashraheel, M. y Alsuri, A. (2022). Improve the accuracy of students admission at universities using machine learning techniques. En *Proceedings of the 2022 7th International Conference on Data Science and Machine Learning Applications (CDMA)*, 127-132. <https://doi.org/10.1109/CDMA54072.2022.00026>

- Bonaccorso, G. (2018). *Machine learning algorithms: Popular algorithms for data science and machine learning* (2nd ed.). Packt Publishing. <https://bit.ly/3VNOg5L>
- Bonaccorso, G. (2018). *Mastering Machine Learning Algorithms: Expert Techniques to Implement Popular Machine Learning Algorithms and Fine-Tune Your Models*. Packt Publishing. <https://bit.ly/4bElf2o>
- Chen, X., Peng, Y., Gao, Y. y Cai, S. (2022). A competition model for prediction of admission scores of colleges and universities in Chinese college entrance examination. *PLOS ONE*, 17(10). <https://doi.org/10.1371/journal.pone.0274221>
- Cunningham, J., Mukhopadhyay, R., Jain, R. R. K., Matayoshi, J., Cosyn, E. y Uzun, H. (2021). Pre-course prediction of at-risk calculus students. En I. Roll, et al. (Eds.), *Artificial Intelligence in Education. AIED 2021. Lecture Notes in Computer Science*, 12749, 124-128. Springer. [https://doi.org/10.1007/978-3-030-78270-2\\_22](https://doi.org/10.1007/978-3-030-78270-2_22)
- Das, A. K. y Rodríguez-Marek, E. (2019). A predictive analytics system for forecasting student academic performance: Insights from a pilot project at Eastern Washington University. En *2019 Joint 8th International Conference on Informatics, Electronics & Vision (ICIEV) and 2019 3rd International Conference on Imaging, Vision & Pattern Recognition (icIVPR)*, 1-6. IEEE. <https://doi.org/10.1109/ICIEV.2019.8858523>
- Das, S. y Cakmak, U. M. (2018). *Hands-On Automated Machine Learning: A Beginner's Guide to Building Automated Machine Learning Systems Using AutoML and Python*. Packt Publishing. <https://bit.ly/3z0lwZC>
- De Castro Rodríguez, D., Días de Lima, M., da Conceição, M. D., de Siqueira, V. S. y Barbosa, R. M. (2019). A data mining approach applied to the High School National Examination: Analysis of aspects of candidates to Brazilian universities. En P. Moura Oliveira et al. (Eds.), *Progress in Artificial Intelligence. EPIA 2019. Lecture Notes in Computer Science*, 11804, 3-14. Springer. [https://doi.org/10.1007/978-3-030-30241-2\\_1](https://doi.org/10.1007/978-3-030-30241-2_1)
- Delahoz-Domínguez, E. J., Guillen-Ibarra, S. y Fontalvo-Herrera, T. (2020). Análisis de la acreditación de calidad en programas de ingeniería industrial y los resultados en las pruebas nacionales estandarizadas, en Colombia. *Formación Universitaria*, 13(1), 127-134. <https://doi.org/10.4067/s0718-50062020000100127>
- Elsevier. (n.d.). *Scopus data*. Elsevier. <https://www.elsevier.com/products/scopus/data>
- Fateh Allah, A. G. (2020). Using machine learning to support students' academic decisions. *Journal of Theoretical and Applied Information Technology*, 98(18), 3778-3795. <https://www.jatit.org/volumes/Vol98No18/11Vol98No18.pdf>
- Gao, Z., Gatpandan, M. P. y Gatpandan, P. H. (2021). Classification decision tree algorithm in predicting students' course preference. In *2021 2nd International Symposium on Computer Engineering and Intelligent Communications (ISCEIC)*, 93-97. <https://doi.org/10.1109/ISCEIC53685.2021.00026>
- García Cruz, J. A., García Díaz, B. L., Guevara Valdiviezo, Y., Ortega Rojas, Y. K., Sakibaru Mauricio, L. A. y Vargas Cárdenas, C. A. (2023). *Inteligencia artificial en la praxis docente:*

vínculo entre la tecnología y el proceso de aprendizaje. Josefrank Pernaleté Lugo. <https://doi.org/10.17613/vqt1-cp64>

- Guevara-Flores, K.-F., Hernandez-Calderon, J.-G. y Soto-Mendoza, V. (2023). Enhancing English proficiency test evaluation: Leveraging artificial intelligence for result classification. En *2023 10th International Conference on Soft Computing & Machine Intelligence*, 183-187. <https://doi.org/10.1109/ISCMI59957.2023.10458530>
- Liu, Q., Wang, X., Huang, X. y Yin, X. (2020). Prediction model of rock mass class using classification and regression tree integrated AdaBoost algorithm based on TBM driving data. *Tunnelling and Underground Space Technology*, 106, 103595. <https://doi.org/10.1016/j.tust.2020.103595>
- Martinez Neda, B. y Gago-Masague, S. (2022). Feasibility of machine learning support for holistic review of undergraduate applications. *Proceedings of the 2022 International Conference on Applied Artificial Intelligence (ICAPAI)*, 1-6. <https://doi.org/10.1109/ICAPAI55158.2022.9801571>
- Mengash, H. A. (2020). Using data mining techniques to predict student performance to support decision making in university admission systems. *IEEE Access*, 8, 55462-55470. <https://doi.org/10.1109/ACCESS.2020.2981905>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D. y Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372(71). <https://doi.org/10.1136/bmj.n71>
- Pastora Alejo, B. y Fuentes Aparicio, A. (2021). La planificación de estrategias de enseñanza en un entorno virtual de aprendizaje. *Revista Científica UISRAEL*, 8(1), 59-76. <https://doi.org/10.35290/rcui.v8n1.2021.341>
- Pentel, A. y Kaiva, L.-L. (2020). Predicting students' state examination results based on previous grades and demographics. En *2020 11th International Conference on Information, Intelligence, Systems and Applications*, 1-6. <https://doi.org/10.1109/IISA50023.2020.9284401>
- Qahmash, A., Ahmad, N. y Algarni, A. (2023). Investigating students' pre-university admission requirements and their correlation with academic performance for medical students: An educational data mining approach. *Brain Sciences*, 13(3) <https://doi.org/10.3390/brainsci13030456>
- Restrepo Gómez, B. (2013). Fundamentos teóricos de la evaluación por competencias: trazabilidad histórica del concepto. *Uni-pluri/versidad*, 13(2), 14-23. <http://bit.ly/4cRKFKV>
- Rudd, G., Meissel, K. y Meyer, F. (2021). Measuring academic resilience in quantitative research: A systematic review of the literature. *Educational Research Review*, 34. <https://doi.org/10.1016/j.edurev.2021.100402>
- Sanabria James, L. A., Pérez Almagro, M. C. y Riascos Hinestroza, L. E. (2020). Pruebas de evaluación Saber y PISA en la Educación Obligatoria de Colombia. *Educatio Siglo XXI*, 38(3), 231-254. <https://doi.org/10.6018/educatio.452891>

- Shea, B. J., Reeves, B. C., Wells, G., Thuku, M., Hamel, C., Moran, J. y Moher, D. (2017). AMSTAR 2: A critical appraisal tool for systematic reviews that include randomised or non-randomised studies of healthcare interventions, or both. *BMJ*, 358. <https://doi.org/10.1136/bmj.j4008>
- Song, Z. y Ke, K. (2023). Prediction for CET-4 based on random forest. *Procedia Computer Science*, 228, 429-437. <https://doi.org/10.1016/j.procs.2023.11.049>
- Soto-Acevedo, M., Abuchar-Curi, A. M., Zuluaga-Ortiz, R. A. y Delahoz-Domínguez, E. J. (2023). A machine learning model to predict standardized tests in engineering programs in Colombia. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 18(3), 211-218. <https://doi.org/10.1109/RITA.2023.3301396>
- Sterne, J. A., Hernán, M. A., Reeves, B. C., Savovic, J., Berkman, N. D., Viswanathan, M. y Moher, D. (2016). ROBINS-I: A tool for assessing risk of bias in non-randomised studies of interventions. *BMJ*, 355, <https://doi.org/10.1136/bmj.i4919>
- Suvon, M. N. I., Siam, S. C., Ferdous, M., Alam, M. y Khan, R. (2022). Masters and doctor of philosophy admission prediction of Bangladeshi students into different classes of universities. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 11(4), 1545-1553. <https://doi.org/10.11591/ijai.v11.i4.pp1545-1553>
- Thomas, P. B., Bego, C. R. y Dourado, A. D. P. (2023). Predicting student retention via expectancy value theory using data gathered before the semester begins. *ASEE Annual Conference & Exposition*. <https://doi.org/10.18260/1-2--43930>
- Vanegas-Ayala, S. C., Leal-Lara, D. D. y Barón-Velandia, J. (2022). Predicción rendimiento estudiantes pruebas saber pro en pandemia junto con las características socioeconómicas: Prediction of student performance saber pro-test in pandemic together with socioeconomic characteristics. *Tecnología Investigación y Academia*, 9(2), 5-16. <https://revistas.udistrital.edu.co/index.php/tia/article/view/19446>
- Whiting, P. F., Rutjes, A. W. S., Westwood, M. E. y QUADAS-2 Group. (2011). QUADAS-2: A revised tool for the quality assessment of diagnostic accuracy studies. *Annals of Internal Medicine*, 155(8), 529-536. <https://doi.org/10.7326/0003-4819-155-8-201110180-00009>
- Wolff, R. F., Moons, K. G. M., Riley, R. D. y PROBAST Group. (2019). PROBAST: A tool to assess the risk of bias and applicability of prediction model studies. *Annals of Internal Medicine*, 170(1), 51-58. <https://doi.org/10.7326/M18-1376>

## CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

### Contribuciones de los/as autores/as:

**Conceptualización:** Orozco Morales, Nathalia; **Validación:** Orozco Morales, Nathalia  
**Análisis formal:** Osorio García, Pável Andrei; **Curación de datos:** Osorio García, Pável Andrei;  
**Redacción-Preparación del borrador original:** Osorio García, Pável Andrei **Redacción-Revisión y Edición:** Orozco Morales, Nathalia **Visualización:** Orozco Morales, Nathalia  
**Supervisión:** Orozco Morales, Nathalia **Administración de proyectos:** Orozco Morales, Nathalia  
**Todos los/as autores/as han leído y aceptado la versión publicada del manuscrito:** Orozco Morales, Nathalia; Osorio García, Pável Andrei.

**Financiación:** Esta postulación requirió financiación de la Corporación Universitaria Minuto de Dios.

**Agradecimientos:** *El presente texto nace del proyecto semillero del programa de especialización en inteligencia artificial de la Corporación Universitaria Minuto de Dios, “Modelos predictivos enfocados a la ejecución de proyectos y mejoras de resultados académicos”.*

### AUTOR/ES:

#### Nathalia Orozco Morales

Corporación Universitaria Minuto de Dios.

Docente investigadora en la especialización en inteligencia artificial de la Corporación Universitaria Minuto de Dios. Magister en Inteligencia Artificial y profesional en Ingeniería Física, con experiencia en la integración de tecnologías avanzadas y métodos científicos en proyectos educativos e investigativos.

[nathalia.orozco@uniminuto.edu](mailto:nathalia.orozco@uniminuto.edu)

**Orcid ID:** <https://orcid.org/0009-0001-8454-2100>

**Google Scholar:** <https://scholar.google.com/citations?hl=es&user=J1UwZ50AAAAJ>

**CvLac:**

[https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod\\_rh=0001489516](https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0001489516)

#### Pável Andrei Osorio García

Corporación Universitaria Minuto de Dios.

Estudiante de la especialización en inteligencia Artificial de la Corporación Universitaria Minuto de Dios, Especialista en Sistemas de la Universidad Nacional de Colombia. Programador Senior Full Stack, con amplia experiencia en el desarrollo de soluciones educativas.

[pavel.osorio@uniminuto.edu.co](mailto:pavel.osorio@uniminuto.edu.co)

**Orcid ID:** <https://orcid.org/0009-0002-9886-743X>

**CvLac:**

[https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod\\_rh=0000126625](https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0000126625)