

Advancing University Education: A Review of Generative AI and Machine Learning in Learning and Innovation

Cerdan-Chanduco, Clara Elvia¹; Doig-Deza, Yvo Augusto¹

¹Universidad Tecnológica del Perú, Perú, c26352@utp.edu.pe, c20339@utp.edu.pe

Abstract—The implementation of generative artificial intelligence (AI) and Machine Learning (ML) is revolutionizing higher education. These technologies enable more personalized teaching, optimize academic management processes, and promote innovative pedagogical methodologies. This study aims to systematically review the state of the art of AI and ML in the university context between 2015 and 2024, based on 50 articles selected from the Scopus database. A mixed methodology was used that combined bibliometric and content analysis to identify trends, technological tools, and their influence on academic performance. The findings highlight ChatGPT, Microsoft Insights, and Turnitin as the most used generative artificial intelligence tools, contributing to academic writing, plagiarism detection, and educational data analysis. Furthermore, evidence shows that the application of machine learning models, such as Random Forest and Support Vector Machine, favors the prediction of student performance and the detection of at-risk students. Despite significant benefits, challenges persist related to ethics, data privacy, and technology dependence. In conclusion, the integration of AI and machine learning drives efficiency in teaching processes and promotes educational innovation; however, it is essential to develop regulatory frameworks and adaptive pedagogical approaches to ensure its sustainable implementation.

Keywords— Generative artificial intelligence, generative ai, machine learning, higher education, academic performance.

Impulsando la Educación Universitaria: Una revisión sobre la IA Generativa y el Machine Learning en el Aprendizaje y la Innovación

Cerdan-Chanduco, Clara Elvia¹; Doig-Deza, Yvo Augusto¹

¹Universidad Tecnológica del Perú, Perú, c26352@utp.edu.pe, c20339@utp.edu.pe

Resumen—La implementación de la inteligencia artificial (IA) generativa y el aprendizaje automático (Machine Learning, ML) está revolucionando la educación superior. Estas tecnologías permiten una enseñanza más personalizada, optimizan los procesos de gestión académica y promueven nuevas metodologías innovadoras en el ámbito pedagógico. Este estudio tiene como objetivo revisar sistemáticamente el estado del arte de la IA y el ML en el contexto universitario entre 2015 y 2024, a partir de 50 artículos seleccionados en la base de datos Scopus. Se utilizó una metodología mixta que combinó el análisis bibliométrico y de contenido con el propósito de identificar tendencias, herramientas tecnológicas y su influencia en el desempeño académico. Los hallazgos resaltan a ChatGPT, Microsoft Insights y Turnitin como las herramientas de inteligencia artificial generativa más empleadas, contribuyendo a la redacción académica, la detección de plagio y el análisis de datos educativos. Además, se evidencia que la aplicación de modelos de aprendizaje automático, como Random Forest y Support Vector Machine, favorece la predicción del rendimiento estudiantil y la detección de alumnos en riesgo. A pesar de los beneficios significativos, persisten desafíos relacionados con la ética, la privacidad de los datos y la dependencia de la tecnología. En conclusión, la integración de la IA y el aprendizaje automático impulsa la eficiencia en los procesos de enseñanza y fomenta la innovación educativa; sin embargo, es fundamental desarrollar marcos regulatorios y enfoques pedagógicos adaptativos para garantizar su implementación sostenible.

Palabras clave—Inteligencia artificial generativa, ia generativa, machine learning, educación universitaria, rendimiento académico.

I. INTRODUCCIÓN

La IA y el aprendizaje automático (ML) han surgido como unas de las principales impulsoras de cambio dentro de la educación superior [1], [2]. Entre otras, estas tecnologías han reformado radicalmente las prácticas educativas establecidas, facilitando la personalización sin precedentes del aprendizaje y mejorando las funcionalidades educativas por medio del procesamiento masivo de datos analíticos y la previsión de desempeños académicos a partir de determinados patrones [3], [4].

Particularmente, ChatGPT y otros modelos avanzados de Inteligencia Artificial generativa han hecho posible asistir en la creación de material educativo, la resolución de problemas complejos, así como mejorar el aprendizaje interactivo. Estas herramientas no solo hacen que el proceso educativo sea más

efectivo, sino que también mejoran la creatividad y las habilidades de pensamiento crítico de los aprendices [5], [6], [7], [8]. Además, los sistemas de recomendación basados en ML han mejorado la toma de decisiones académicas, incluyendo elecciones relacionadas con la selección de cursos y la identificación temprana de estudiantes que están en riesgo académico [9], [10], [11].

Además, el uso de la IA en la educación ha resultado en un cambio más allá de las iniciativas de la pedagogía tradicional [12], [13]. En particular, los modelos pedagógicos modernos se vuelven más flexibles y adaptables [14], [15]. Gracias a la AI, se han desarrollado entornos de aprendizaje híbridos, que permiten la combinación del aprendizaje en el aula y en línea para proporcionar la interacción más efectiva entre estudiantes y docentes [16], [17]. Tales entornos impulsan la participación activa del estudiante, estimulan el autoaprendizaje y promueven la colaboración en línea, todo lo cual es crucial en la dinámica de la educación moderna globalizada.

Por el contrario, la instalación de tecnologías IA y ML ha sido personalizada u optimizada en lo que se refiere a la evaluación académica [18]. Los datos comerciales lo han hecho posible para rastrear los registros de los estudiantes en cualquier momento, encontrar los aspectos de asistencia a la clase y la instrucción, y el personal de trabajo y, por lo tanto, sentirse ayuno [19]. Todos estos factores le han permitido crear sistemas de evaluación justos y efectivos, el desarrollo integral de estudiantes.

De forma global, la influencia de la IA en la enseñanza superior se realiza con la posibilidad dada a las instituciones de manejar grandes cantidades de datos que les permiten la creación de decisiones estratégicas en relación con la realización del programa, la asignación de recursos y la mejora de la calidad [11], [20]. La toma de decisiones analíticas se ha vuelto crítica para la competitividad de universidades en un mundo digital y global.

A pesar de ello, la rápida expansión de este tipo de tecnologías plantea importantes cuestiones, particularmente en relación con la moralidad, la privacidad de datos y la igualdad de acceso a los recursos tecnológicos. Por estas razones, es

crucial que se creen marcos de regulación para controlar y alentar el uso de IA en la educación también en base a algunos principios para garantizar que todos los estudiantes puedan beneficiarse de esta tecnología [10]. Además, la necesidad de formar a los estudiantes en competencias digitales críticas se vuelve cada vez más relevante, especialmente para evaluar y gestionar de manera efectiva la información generada por estas tecnologías.

En este contexto, la literatura académica reciente destaca la importancia de integrar la IA y el ML de manera sostenible en los entornos educativos, considerando tanto sus beneficios como los riesgos asociados. Se subraya la necesidad de fomentar una cultura de innovación responsable, que no solo priorice el rendimiento académico, sino también el bienestar y el desarrollo integral de los estudiantes [16], [17].

Por todo lo expuesto, la pregunta de investigación generada es: **¿Cuál es el estado del arte sobre la inteligencia artificial y el machine learning en la educación superior durante el 2015 al 2024 en Scopus?**

Además, se resalta 3 preguntas complementarias, las cuáles siguen la estructura PIO (Población, Intervención, Resultados):

PC1: ¿Qué herramientas de IA generativa son las más utilizadas en el ámbito universitario, y cuáles son sus características técnicas y funcionalidades principales?

PC2: ¿Qué impacto tiene la aplicación de IA generativa en el rendimiento académico de los estudiantes universitarios en comparación con métodos tradicionales?

PC3: ¿En qué contextos de uso se aplica la IA generativa en la formación de estudiantes universitarios, y qué competencias desarrollan los estudiantes a través de su uso?

Por ende, el objetivo general del estudio es estudiar el estado del arte sobre la inteligencia artificial y el machine learning en la educación superior durante el 2015 al 2024 en Scopus. Por tanto, los objetivos específicos propuestos son: revisar el estado del arte a través de indicadores bibliométricos, revisar el contenido de los hallazgos temáticos, realizar un análisis comparativo-descriptivo de los hallazgos temáticos.

II. METODOLOGÍA

Este estudio se basa en un enfoque de investigación mixta, combinando el análisis cuantitativo de datos bibliométricos con un examen cualitativo de los hallazgos temáticos. De esta manera, se elabora una revisión sistemática de la literatura (RSL) que permite identificar tendencias y patrones relevantes en la investigación [21]. El objetivo es realizar una síntesis crítica, minuciosa y replicable sobre la bibliografía incluida en la RSL para declarar hallazgos de nueva evidencia científica a lo largo del tiempo, lo que se

expresa mejor con ayuda de gráficos y tablas que ayudan a un fácil entendimiento [22].

Al realizar la investigación, se optó por seguir los lineamientos de PRISMA, el cual tiene un antecedente del 2009 que recientemente fue actualizado por la Declaración PRISMA 2020, donde incorporan algunos puntos extras para una mejor identificación de registros, y procedimientos estandarizados, de manera que se garantice un reporte de calidad replicable [23],[24]. Durante los últimos 5 años desde que fue publicado PRISMA 2020, se han evidenciado investigaciones de calidad que brindan soluciones y alcances a la comunidad científica en diferentes ejes temáticos, por tanto, ha generado un aumento en el volumen de publicaciones sobre este tipo de informes para resolver diferentes problemáticas a nivel global [25],[26].

La identificación de registros inicia con la formulación de una ecuación de búsqueda diseñada para recopilar información de la base de datos Scopus, la cual es administrada por la empresa Elsevier, con sede en los Países Bajos. El proceso de búsqueda inicio con la formulación de la ecuación de búsqueda, la que se formó a partir de palabras clave de búsqueda en su versión inglés tales como: inteligencia artificial, machine learning, rendimiento académico, no graduado, y considerando operadores booleanos como: AND, OR, ALL, resultando en la siguiente cadena:

(ALL ("artificial intelligence" OR "educational technology" OR "machine learning") AND ALL ("academic achievement" OR "academic performance") AND ALL (undergraduate))

Cabe resaltar que, el proceso de la búsqueda se realizó el 30/01/2025, donde se tuvo un resultado inicial de 21,688 documentos encontrados. Una vez establecido el inicio de la identificación, fue necesario designar normas de elegibilidad para garantizar calidad en la selección de estudios incluidos en la RSL, estos se dividen por criterios de inclusión y exclusión, tal como se muestra en la tabla I.

TABLA I
PARÁMETROS DE ELEGIBILIDAD

Criterios de Exclusión	
CE1	Estudios que no contengan una o más variables de investigación.
CE2	Investigaciones publicadas fuera del periodo 2015-2024.
CE3	Estudios que no demuestren datos empíricos sobre el rendimiento de los estudiantes.
CE4	Investigaciones que no utilicen herramientas de inteligencia artificial generativa o machine learning.
Criterios de Inclusión	
CI1	Estudios pertenecientes a la categoría “Article” (artículo científico).
CI2	Investigaciones que no se encuentren en el proceso final de indexación.
CI3	Investigaciones que no mencionen las competencias desarrolladas gracias a la inteligencia artificial generativa o el machine learning.

La selección de estudios se realizó siguiendo los lineamientos establecidos por la Declaración PRISMA 2020.

El proceso de búsqueda fue ejecutado en la base de datos Scopus el 30 de enero de 2025. En una primera etapa, se aplicó una estrategia de búsqueda amplia en todos los campos indexados, obteniéndose un total de 21,688 registros iniciales. Posteriormente, con el propósito de incrementar la precisión temática y recuperar investigaciones directamente vinculadas con el objeto de estudio, la búsqueda se refinó a los campos título, resumen y palabras clave, reduciendo el total a 204 documentos. En la siguiente fase, se aplicó el filtro de acceso abierto (Open Access), con la finalidad de garantizar la disponibilidad del texto completo para su lectura crítica y análisis metodológico, obteniéndose 83 registros. Luego, se incorporó la delimitación temporal correspondiente al periodo 2015–2024, en concordancia con los objetivos de la investigación, lo que permitió reducir la muestra a 76 estudios. Posteriormente, se seleccionaron únicamente documentos clasificados por Scopus como artículos científicos, alcanzando un total de 68 registros elegibles. Finalmente, se desarrolló una revisión manual de elegibilidad mediante apoyo de Microsoft Excel, orientada a verificar la pertinencia temática, eliminar estudios con escasa relación con la educación universitaria, controlar duplicidades conceptuales y descartar investigaciones que no respondían de manera directa a las preguntas planteadas en la revisión. Como resultado de este último proceso de cribado, la muestra final quedó conformada por 50 artículos científicos incluidos en la revisión sistemática de literatura.

(Análisis de contenido), Cran R-Bibliometrix-VOSviewer-MS Power BI (Análisis bibliométrico).

III. RESULTADOS Y DISCUSIÓN

3.1 RESULTADOS BIBLIOMÉTRICOS

El primer indicador bibliométrico a analizar es un esquema de redes de superposición basado en 2 indicadores: el promedio de citaciones totales por palabras clave y el promedio de años de publicación por cada palabra. Se identificaron 18 clusters en las redes, con diferente fuerza de enlace. El gráfico ha sido elaborado en base a 154 palabras clave recolectadas en los 50 estudios incluidos, donde se observa como las palabras varían según la fecha de publicación y el año de antigüedad. Se logró identificar que cada palabra clave identificada es inversa a su homólogo en el otro gráfico demostrando que una palabra clave con mayor antigüedad por lo general tiene mayores citaciones, mientras que palabras clave con menor antigüedad (recientes) poseen una menor cantidad de citaciones totales (posiblemente porque la literatura que citan estas palabras clave aún no están indexadas en Scopus). Entre las palabras clave con mayor ocurrencia se encontraron a: machine learning (aprendizaje automático = 13 ocurrencias), academic performance (rendimiento académico = 12 ocurrencias), learning analytics (analítica del aprendizaje = 8 ocurrencias), artificial intelligence (inteligencia artificial = 11 ocurrencias).




Fig. 1. Flujo de la búsqueda en formato PRISMA 2020

Se utilizaron las técnicas de análisis y recopilación de datos. Asimismo, las herramientas informáticas: MS Excel




Fig. 2 Esquema de superposición de redes de keywords; promedio: citaciones – palabras clave (Fuente: VOSviewer)

La Fig 3. hace referencia a la distribución por países según los autores analizados en un mapa coroplético. Se

identificó que los países con un porcentaje mayor a 5% fueron 6: China en la cabeza con 14 autores identificados, estando representado por el 13% del total; por detrás, México cuenta con 11 investigadores. El total de países identificados asciende a 29, entre los cuales figura Perú con 4 autores que investigan sobre la aplicación de la inteligencia artificial generativa y el aprendizaje automático en el ámbito de la educación universitaria.




Fig. 3 Gráfico coroplético de la distribución de los autores de los artículos incluidos. (Fuente: Bibliometrix)

La Fig. 4 es un resumen de indicadores donde se destaca la producción científica anual (barras azules) de los 50 estudios en el tiempo con respecto a la cantidad de citas totales en el intervalo temporal delimitado. Asimismo, se observa que el mayor volumen de artículos fue publicado en el 2024, sin embargo, la mayor cantidad de citas reside en el 2022. Además, años como el 2016, 2018 no presentan artículos sobre el tema estudiado, siendo el 2015, 2017 y 2019 los años con la menor cantidad de estudios publicados. Por otro lado, se hace un detalle de la proporción de citas a nivel porcentual de cada año, viendo la variación a escala con respecto al año con mayor cantidad de citas, donde se evidencia la diferencia entre el 2019 que tiene 15 citas acumuladas estando representado por el 3%.

Con respecto al gráfico de anillo que se observa abajo, hace una comparativa de las 5 editoriales más relevantes en base a la cantidad de citas acumuladas, donde vemos que Springer destaca con el 38%, siendo el otro escenario la matriz del lado derecho, donde ahora se ve cuáles son las 5 revistas más citadas durante los años, donde la revista “Smart Learning Environments” destaca con 278 citas acumuladas. Algo importante es que la revista posee un CiteScore 2023 de 13.2 y está posicionada en Cuartil 1 (Q1) según el Scimago Journal Rank.

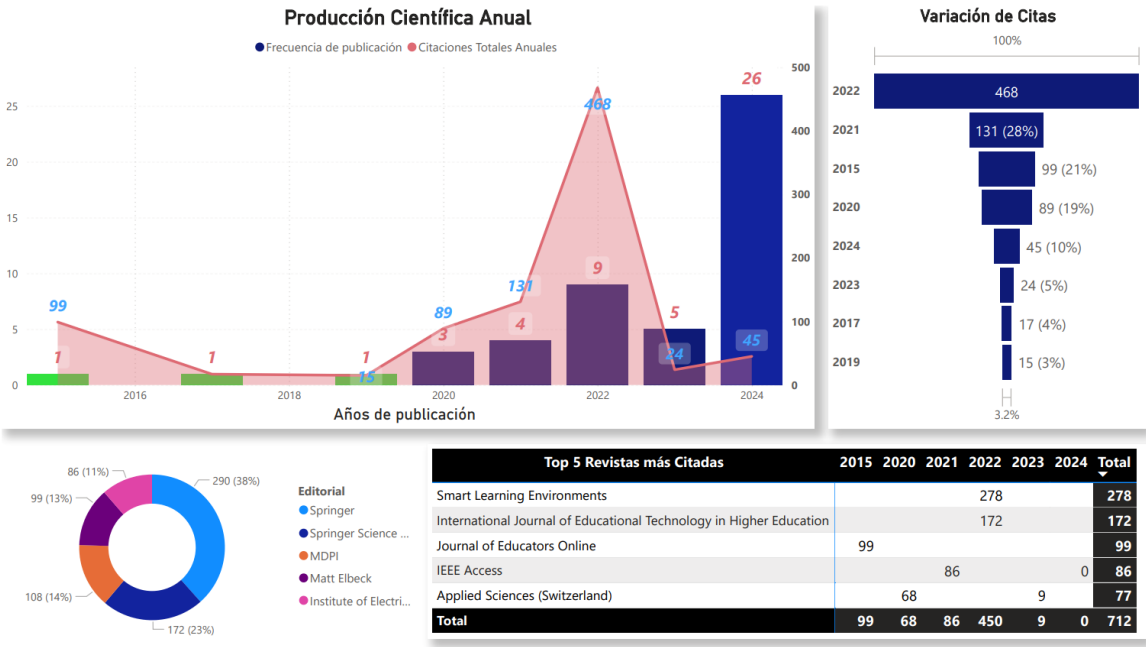


Fig. 4 Resumen de indicadores en base a la suma de total de citas. (Fuente: MS Power BI)

3.2 RESULTADOS DE CONTENIDO

Se agrupan las herramientas tecnológicas utilizadas en los estudios, con un énfasis en aquellas basadas en inteligencia artificial (IA), como ChatGPT, SECTRA Workstation, y Complete Anatomy. Se resalta que la implementación de estas herramientas optimiza la eficiencia en la ejecución de diversas

tareas y fortalece la comprensión académica. Las columnas permiten observar la frecuencia de uso, los contextos de aplicación y los resultados obtenidos, lo que facilita la identificación de patrones de adopción tecnológica en la educación superior.

TABLA II

TIPO DE HERRAMIENTA IA O MACHINE LEARNING Y DETALLE

Herram.	Descripción de la herramienta	Ref.
ChatGPT (OpenAI)	ChatGPT (3.5 y 4.0): Asistente de inteligencia artificial diseñado para la generación de contenido, la resolución de consultas y el apoyo en tareas de programación y redacción académica. Grammarly®: Herramienta de corrección gramatical enfocada en mejorar la calidad de los textos académicos. QuillBot®: Plataforma de parafraseo que permite reformular y optimizar la redacción de textos académicos. SPATIAL.io: Entorno de realidad virtual que facilita clases interactivas en espacios tridimensionales. Sistema de Feedback basado en ML-LA: Tecnología de inteligencia artificial que analiza datos estudiantiles para proporcionar retroalimentación personalizada.	[27], [28], [29], [30], [31], [32], [33], [34], [35], [36], [37]
Herramientas de IA	Chatbots: Asistentes impulsados por inteligencia artificial que facilitan interacciones dinámicas en el proceso de aprendizaje, responden preguntas en tiempo real y brindan retroalimentación educativa personalizada. Polivr Ecosystem: Plataforma diseñada para el análisis de datos de aprendizaje en entornos Git, incorporando herramientas para la anonimización de información, la extracción de métricas de rendimiento y la visualización del progreso académico. Fuzzy Bayesian Intelligent Tutoring System (FB-ITS): Sistema de tutoría adaptativo que emplea lógica difusa y redes bayesianas para evaluar el rendimiento estudiantil, personalizando el contenido de aprendizaje en función del progreso individual.	[38], [39], [40]
Herramientas de Microsoft	Microsoft Editor: Asistente de inteligencia artificial diseñado para la corrección gramatical y ortográfica. Microsoft Reading Progress: Plataforma que emplea inteligencia artificial para evaluar la fluidez en la lectura y la pronunciación, identificando errores frecuentes en el proceso. Microsoft Reflect: Herramienta para que los estudiantes expresen emociones, ayudando a identificar estados como estrés o fatiga. Microsoft Insights: Analiza datos de participación y desempeño académico en Microsoft Teams, mostrando tendencias en calificaciones. Turnitin: Herramienta para detectar similitudes en textos y mejorar la originalidad del contenido académico.	[41]
Modelos de Aprendizaje Automático	Redes Neuronales Artificiales (ANN): Algoritmo inspirado en la estructura neuronal, basado en perceptrones multicapa (MLP) con retropropagación, implementado en TensorFlow y Keras. Naïve Bayes (NB): Modelo de clasificación basado en el Teorema de Bayes, que emplea la suposición de independencia condicional entre variables para realizar análisis predictivos. Support Vector Machine (SVM): Algoritmo supervisado para predicción de	[42], [43], [44], [45], [46], [47], [48], [49], [50]

	rendimiento académico, optimizado con kernels (RBF, lineal, polinomial, sigmoide) para mayor precisión. Random Forest: Modelo basado en múltiples árboles de decisión, utilizado para identificar factores clave que afectan el rendimiento académico. Extreme Gradient Boosting (XGBoost): Algoritmo de aprendizaje automático eficiente para clasificación y predicción de rendimiento académico. Classification and Regression Tree (CART): Modelo de árbol de decisión para clasificación y predicción de resultados académicos. 1D Convolutional Neural Network (1DCNN-CBAM): Red neuronal convolucional con módulo de atención, utilizada para mejorar la predicción del rendimiento académico. K-Nearest Neighbors (KNN): Algoritmo de clasificación basado en la cercanía de datos para predecir resultados académicos. Moodle (LMS): Plataforma de gestión de aprendizaje que permite implementar ejercicios guiados, retroalimentación inmediata y monitoreo del progreso del estudiante. Análisis de redes sociales (SNA): Se empleó EV centrality como métrica para evaluar la influencia de los estudiantes en los debates.	
Random Forest	K-Nearest Neighbors (KNN): Algoritmo de clasificación basado en la cercanía entre observaciones, utilizado para predecir rendimiento académico y clasificar estudiantes según sus patrones de aprendizaje. Support Vector Machine (SVM): Modelo supervisado para clasificación y regresión, optimizado con diferentes kernels para mejorar la precisión en la predicción del rendimiento académico. Decision Tree (DT): Algoritmo basado en reglas jerárquicas para clasificar el rendimiento estudiantil y predecir riesgos de deserción. Random Forest (RF): Modelo de ensamblaje basado en múltiples árboles de decisión, utilizado para predecir rendimiento académico y evaluar factores que influyen en el desempeño estudiantil. Naïve Bayes (NB): Modelo probabilístico basado en el Teorema de Bayes para evaluar la influencia de variables demográficas y académicas en el rendimiento estudiantil. Extreme Gradient Boosting (XGBoost) y ADA Boosting: Algoritmos de ensamblaje que integran múltiples árboles de decisión con el propósito de incrementar la precisión en la predicción del rendimiento académico. Fuzzy ANFIS: Sistema que combina redes neuronales y lógica difusa para mejorar la predicción de resultados educativos y fusionar datos de estudiantes y docentes. Microsoft Band: Dispositivo con sensores para monitorear la actividad física y analizar datos mediante algoritmos de aprendizaje automático como Random Forest.	[51], [52], [53], [54], [55], [56], [56], [57], [58], [59], [60], [61], [62], [63], [64], [65], [66]

	K-means Clustering: Método de agrupamiento que clasifica a los estudiantes según sus patrones de estudio, niveles de asistencia y grado de participación en actividades académicas. Apriori Algorithm: Algoritmo de minería de datos para identificar relaciones entre el comportamiento estudiantil y su rendimiento académico. Stacked Integrated Learning Models: Modelo que combina RF, GBT y XGBoost para mejorar la precisión en la predicción del rendimiento académico.	
KNUSTbot Flow XO	KNUSTbot: Chatbot basado en WhatsApp que utiliza procesamiento de lenguaje natural (NLP) para responder preguntas sobre programación y ofrecer enlaces a recursos educativos. Flow XO: Plataforma para crear chatbots sin necesidad de programación, que emplea aprendizaje automático y NLP para interpretar preguntas y generar respuestas.	[67]
CATBoost Classifier	CATBoost Classifier (CATC): Algoritmo de gradient boosting optimizado para manejar datos categóricos, utilizado en la predicción del rendimiento académico. VAO (Victoria Amazonica Optimization): Algoritmo de optimización inspirado en la planta Victoria Amazonica, aplicado para mejorar el rendimiento de modelos en entornos dinámicos. ARO (Artificial Rabbits Optimization): Algoritmo basado en el comportamiento de evasión de conejos, utilizado para la optimización de hiperparámetros en modelos de inteligencia artificial.	[68]
Realidad Aumentada (AR)	Realidad Aumentada (AR): Se aplicaron materiales diseñados con tecnología AR para mejorar la enseñanza de vocabulario en inglés.	[69]
Rede Neuronales Artificiales (ANN)	Red neuronal artificial (ANN - Multilayer Perceptron Model): Algoritmo de aprendizaje supervisado que emplea retropropagación para ajustar los pesos y técnicas de normalización para optimizar el rendimiento	[70]
Encuestas en línea	Encuesta sobre Tecnologías de Aprendizaje: Instrumento diseñado para analizar la frecuencia de uso y la percepción de utilidad de diversas tecnologías en el ámbito universitario. Affinity for E-Learning Questionnaire (AEQ): Cuestionario orientado a medir la afinidad de los estudiantes con el aprendizaje en línea, evaluando su confianza en el uso de herramientas tecnológicas. Peritraumatic Dissociative Experiences Questionnaire (PDEQ): Instrumento desarrollado para medir experiencias disociativas en respuesta a situaciones traumáticas. COVID-19 Student Stress Questionnaire (CSSQ): Cuestionario que evalúa el estrés académico asociado a la pandemia de COVID-19. Coronavirus Anxiety Scale (CAS): Escala para medir la ansiedad relacionada con el COVID-19 en estudiantes.	[71], [72], [73]
Mytelemap	Mytelemap: Herramienta web para la visualización de conocimiento mediante mapas conceptuales, que ofrece recomendaciones de contenido educativo	[74]

	basadas en Google API.	
SECTRA Workstation IDS7	SECTRA Workstation IDS7: Software de disección virtual que permite la exploración detallada de estructuras anatómicas utilizando casos clínicos reales en un entorno digital. Complete Anatomy App: Aplicación educativa para la disección virtual en 3D, utilizada para explorar órganos y complementar la enseñanza teórica y práctica junto con SECTRA Workstation.	[75]

La siguiente tabla resume los principales hallazgos sobre el impacto de las herramientas de inteligencia artificial en el rendimiento académico. Los resultados muestran un efecto positivo significativo, reflejado en mejoras en las calificaciones, el desempeño en evaluaciones y la eficiencia en el aprendizaje.

TABLA III
IMPACTO EN EL RENDIMIENTO ACADÉMICO

Resultados	Rendimiento Académico	Ref.
Aumento en la participación estudiantil	Se identificó un impacto positivo en el rendimiento académico de los estudiantes que completaron al menos el 75% de los ejercicios guiados, reflejado en una tasa de aprobación del 59.4%, en contraste con el 41.5% de aquellos que no hicieron uso de estos recursos. Asimismo, los estudiantes que participaron en mayor medida lograron mejores calificaciones en los exámenes finales. Este vínculo presentó una significancia estadística ($p = 0.023$) y, aunque la asociación fue baja, resultó relevante (Cramér's $V = 0.167$).	[47]
Impacto positivo general	La integración de herramientas de IA y estrategias de aprendizaje activo mostró un impacto positivo en el rendimiento académico, evidenciado en un aumento en las tasas de aprobación (59.4% frente a 41.5%) y mejoras en las calificaciones ($p = 0.023$). Modelos predictivos como Random Forest alcanzaron una precisión del 92% en la identificación de la retención estudiantil, lo que permitió detectar de manera temprana a alumnos en riesgo. Además, la consistencia en el proceso de aprendizaje y la autoeficacia académica estuvieron vinculadas a un mejor desempeño. Aunque la IA optimizó la eficiencia del aprendizaje, su influencia en las calificaciones no fue directa.	[30], [32], [39], [41], [42], [54], [61], [71], [72], [73]
Impacto en la motivación estudiantil	El uso de ChatGPT mostró un impacto positivo en el rendimiento académico, con un 65% de los estudiantes reportando una mejora en su comprensión de los contenidos y una mayor eficiencia en la realización de tareas. Se identificó una correlación positiva entre la motivación y el desempeño académico ($r = 0.21$, $p < 0.05$), siendo más evidente en evaluaciones de vocabulario. No obstante, aún existen desafíos, como la falta de directrices claras para la integración de la inteligencia artificial en la educación y preocupaciones sobre una posible dependencia excesiva de estas herramientas.	[29], [69]
Mejora en el rendimiento académico	El uso de modelos de inteligencia artificial como SVM, ANN y Random Forest contribuyó a la mejora del rendimiento	[31], [34], [35], [37], [38], [40],

	académico, alcanzando precisiones de hasta el 100% en la predicción del desempeño estudiantil y en la identificación de alumnos en riesgo. Factores como la asistencia, la calidad del sueño y el esfuerzo académico mostraron una relación positiva con mejores calificaciones. Asimismo, herramientas como ChatGPT y SPATIAL.io optimizaron la eficiencia y la motivación en el aprendizaje; sin embargo, su impacto en el GPA fue limitado.	[43], [44], [45], [46], [49], [50], [51], [52], [53], [55], [56], [57], [58], [59], [60], [62], [63], [64], [65], [66], [67], [68], [70], [74]
Mejora en habilidades y competencias	El empleo de ChatGPT y herramientas de simulación como SECTRA y Complete Anatomy tuvo un efecto positivo en el rendimiento académico, reflejado en mejoras en las calificaciones de exámenes y asignaciones, con tasas de aprobación que alcanzaron el 92%. Se identificó una correlación positiva entre el uso frecuente de ChatGPT y mejores resultados académicos, explicando hasta un 17.3% del incremento en el desempeño estudiantil. No obstante, persisten desafíos como la posible dependencia de la inteligencia artificial, ciertas limitaciones en el desarrollo del pensamiento crítico y la falta de impacto significativo en el aprendizaje colaborativo.	[27], [28], [33], [36], [75]

La última tabla presenta una síntesis de las competencias adquiridas por los estudiantes, los contextos de aplicación de las herramientas de inteligencia artificial y las futuras líneas de investigación propuestas por los autores. Entre las competencias más destacadas se encuentran el pensamiento crítico, la creatividad, la alfabetización digital y la capacidad de resolución de problemas. Además, la estructura de la tabla permite analizar cómo estas habilidades varían en función del entorno educativo y la herramienta utilizada.

TABLA IV
PRINCIPALES COMPETENCIAS DESARROLLADAS, CONTEXTO Y LÍNEAS DE INVESTIGACIÓN

Competencias	Contexto	Líneas de Investigación	Ref.
Autonomía en el Aprendizaje	Educación Superior	Gamificación	[67]
	Educación Superior	Otras Líneas de Investigación	[66]
	Educación Superior	Personalización del Aprendizaje	[40]
	Entorno Académico General	Personalización del Aprendizaje	[52]
	Programación	Otras Líneas de Investigación	[27]
Competencias Digitales	Educación Superior	IA en Educación	[35]
	Entorno Académico General	Otras Líneas de Investigación	[29], [75]
	Programación	Otras Líneas de Investigación	[39]
Competencias Transversales	Ciencias de la Computación	Otras Líneas de Investigación	[38]
	Entorno Académico	IA en Educación	[64]

	General		
	Entorno Académico General	Otras Líneas de Investigación	[28], [37], [42], [46], [48], [51], [54]
Creatividad e Innovación	Entorno Académico General	Otras Líneas de Investigación	[50], [62], [68]
Pensamiento Crítico	Aprendizaje en Línea	Otras Líneas de Investigación	[72], [73]
	Ciencias de la Computación	Gamificación	[60]
	Educación Superior	Otras Líneas de Investigación	[34], [41]
	Entorno Académico General	IA en Educación	[74]
	Entorno Académico General	Otras Líneas de Investigación	[30], [31], [32], [33], [36], [44], [47], [49], [55], [57], [59], [69], [71]
	Entorno Académico General	Personalización del Aprendizaje	[63]
Resolución de Problemas y Toma de Decisiones	Aprendizaje en Línea	Otras Líneas de Investigación	[43], [45]
	Ciencias de la Computación	Otras Líneas de Investigación	[61], [65]
	Educación Superior	Otras Líneas de Investigación	[53], [58], [70]
	Entorno Académico General	Otras Líneas de Investigación	[48], [56]

En respuesta a la PC1 y considerando lo expuesto anteriormente, se resalta que ChatGPT es la herramienta de inteligencia artificial generativa más utilizada en el ámbito universitario. Su popularidad se debe a su capacidad para generar textos de manera coherente, brindar apoyo en la redacción académica y responder consultas complejas en tiempo real [27], [52], [70]. Además, herramientas como Microsoft Insights, Turnitin, QuillBot y Grammarly son ampliamente empleadas para el análisis de datos académicos, la detección de plagio y la reformulación de textos académicos [36], [57], [66]. En el campo de las ciencias de la salud, plataformas como SECTRA Workstation y Complete Anatomy facilitan la simulación tridimensional de estructuras anatómicas, lo que contribuye a una mejor comprensión visual y espacial [48], [49].

Los resultados obtenidos evidencian que la evolución del uso de inteligencia artificial y machine learning en la educación superior no ha sido homogénea durante el periodo analizado, sino que presenta cambios marcados según el avance tecnológico y las necesidades institucionales. En una primera etapa, entre 2015 y 2020, predominó la aplicación de modelos de aprendizaje automático orientados a la predicción del rendimiento académico, identificación de estudiantes en riesgo y análisis de factores asociados al desempeño. En este contexto, algoritmos como Random Forest, Support Vector Machine, Naïve Bayes y redes neuronales artificiales fueron

recurrentemente utilizados debido a su capacidad predictiva y utilidad para la toma de decisiones académicas. A partir de 2023, se observa una transición significativa hacia herramientas de inteligencia artificial generativa, especialmente ChatGPT, Grammarly y QuillBot, cuyo uso se concentró en actividades de redacción, tutoría automática, retroalimentación inmediata y apoyo al aprendizaje autónomo. [29], [30], [34], [38], [45], [56], [59], [64].

En relación con el rendimiento académico, la evidencia reporta resultados favorables, aunque con distintos niveles de solidez metodológica. Los estudios basados en modelos predictivos presentan indicadores cuantificables de precisión, llegando en algunos casos a valores superiores al 90% en la detección temprana de estudiantes con bajo desempeño o riesgo de deserción. Por otro lado, las investigaciones sobre IA generativa muestran mejoras en motivación, eficiencia y percepción de utilidad, aunque en numerosos casos dependen de encuestas de satisfacción, autopercepción estudiantil o diseños transversales. Esto permite inferir que, si bien la IA generativa presenta alto potencial pedagógico, aún existe limitada evidencia longitudinal o experimental que demuestre impactos sostenidos sobre indicadores académicos duros, como GPA, tasas de aprobación o retención estudiantil [31], [39], [41], [43], [58], [69], [72], [75].

A pesar de los resultados favorables, la investigación presenta ciertas limitaciones. En primer lugar, algunos estudios se centran en contextos específicos, lo que dificulta la extrapolación de los hallazgos a un nivel global [33], [42]. Asimismo, la ausencia de análisis longitudinales en varias investigaciones impide evaluar el impacto a largo plazo de la inteligencia artificial generativa en la educación superior [35]. También se identifican posibles sesgos derivados del uso de muestras reducidas o no representativas, así como la falta de consideración de factores psicosociales que podrían influir en el desempeño académico.

Se recomienda llevar a cabo estudios longitudinales. Además, sería relevante examinar su impacto en diferentes disciplinas y contextos educativos con el fin de identificar variaciones significativas en su efectividad. Las investigaciones futuras deberían incluir variables psicosociales, como la motivación, el estrés académico y la interacción social, para obtener una perspectiva más completa del proceso de aprendizaje.

IV. CONCLUSIONES

En conclusión, este estudio ofrece una perspectiva integral sobre el estado del arte de la inteligencia artificial (IA) y el aprendizaje automático (ML) en la educación superior entre 2015 y 2024, a partir del análisis de 50 artículos indexados en Scopus. Se ha identificado que los años con mayor producción académica fueron 2024 y 2022, siendo este último el que acumuló la mayor cantidad de citaciones.

Además, la adopción de herramientas de IA generativa, como ChatGPT, Microsoft Insights, Turnitin y plataformas especializadas en simulación como SECTRA Workstation, ha contribuido significativamente a la mejora del rendimiento académico. Estas tecnologías han facilitado la generación de contenido, la detección de plagio, el análisis de datos y la comprensión de conceptos complejos. Asimismo, modelos de ML como SVM, Random Forest y Naïve Bayes han demostrado una alta precisión en la predicción del desempeño estudiantil y en la identificación de alumnos en riesgo, lo que permite implementar estrategias de intervención temprana y personalizadas.

Asimismo, se resalta que la inteligencia artificial generativa no solo influye en el rendimiento académico, sino que también favorece el desarrollo de competencias esenciales para el siglo XXI, como el pensamiento crítico, la creatividad, la alfabetización digital y la resolución de problemas. No obstante, se han identificado desafíos relacionados con una posible dependencia excesiva de estas tecnologías, así como la necesidad de establecer regulaciones que garanticen un uso ético y equilibrado en el ámbito educativo.

En este contexto, los hallazgos del estudio permiten concluir que la incorporación de inteligencia artificial y aprendizaje automático en la educación superior mejora la eficiencia del aprendizaje, optimiza los procesos educativos y fomenta un entorno académico más dinámico e interactivo.

REFERENCIAS

- [1] M. A. Arbulú Ballesteros *et al.*, «The Sustainable Integration of AI in Higher Education: Analyzing ChatGPT Acceptance Factors Through an Extended UTAUT2 Framework in Peruvian Universities», *Sustainability*, vol. 16, n.º 23, p. 10707, dic. 2024, doi: 10.3390/su162310707.
- [2] R. Sandu, E. Gide, y M. Elkhodr, «The role and impact of ChatGPT in educational practices: insights from an Australian higher education case study», *Discov Educ*, vol. 3, n.º 1, p. 71, jun. 2024, doi: 10.1007/s44217-024-00126-6.
- [3] M. Charytanowicz, M. Zola, y W. Suszyński, «The impact of the COVID-19 pandemic on higher education: Assessment of student performance in computer science», *PLoS ONE*, vol. 19, n.º 8, p. e0305763, ago. 2024, doi: 10.1371/journal.pone.0305763.
- [4] D. I. Galon, «The impact of distance learning on tourism and hospitality education during the SARS-CoV-2 pandemic in Region VI, Western Visayas», *Int. j. adv. appl. sci.*, vol. 11, n.º 10, pp. 1-6, oct. 2024, doi: 10.21833/ijaas.2024.10.001.
- [5] N. S. Alotaibi, «The Impact of AI and LMS Integration on the Future of Higher Education: Opportunities, Challenges, and Strategies for Transformation», *Sustainability*, vol. 16, n.º 23, p. 10357, nov. 2024, doi: 10.3390/su162310357.
- [6] M. Almulla y S. I. Ali, «The Changing Educational Landscape for Sustainable Online Experiences: Implications of ChatGPT in Arab Students' Learning Experience», *IJLTER*, vol. 23, n.º 9, pp. 285-306, sep. 2024, doi: 10.26803/ijlter.23.9.15.
- [7] Z. Khan, A. Ali, D. M. Khan, y S. Aldahmani, «Regularized ensemble learning for prediction and risk factors assessment of students at risk in the post-COVID era», *Sci Rep*, vol. 14, n.º 1, p. 16200, jul. 2024, doi: 10.1038/s41598-024-66894-1.
- [8] E. J. Delahoz-Domínguez y R. Hijón-Neira, «Recommender System for University Degree Selection: A Socioeconomic and Standardised

- Test Data Approach», *Applied Sciences*, vol. 14, n.º 18, p. 8311, sep. 2024, doi: 10.3390/app14188311.
- [9] B. Tang, S. Li, y C. Zhao, «Predicting the Performance of Students Using Deep Ensemble Learning», *J. Intell.*, vol. 12, n.º 12, p. 124, dic. 2024, doi: 10.3390/jintell12120124.
- [10] D. Zhang, K.-W. Mui, M. Masullo, y L.-T. Wong, «Application of Machine Learning Techniques for Predicting Students' Acoustic Evaluation in a University Library», *Acoustics*, vol. 6, n.º 3, pp. 681-697, jul. 2024, doi: 10.3390/acoustics6030037.
- [11] K. Wang, «Optimized ensemble deep learning for predictive analysis of student achievement», *PLoS ONE*, vol. 19, n.º 8, p. e0309141, ago. 2024, doi: 10.1371/journal.pone.0309141.
- [12] A. M. Sánchez-Sánchez, J. D. Mello-Román, M. Segura, y A. Hernández, «Identifying the Determinants of Academic Success: A Machine Learning Approach in Spanish Higher Education», *Systems*, vol. 12, n.º 10, p. 425, oct. 2024, doi: 10.3390/systems12100425.
- [13] N. Joudieh *et al.*, «Higher education in the era of artificial intelligence: academic freedom as a case study», *Discov Sustain*, vol. 5, n.º 1, p. 220, ago. 2024, doi: 10.1007/s43621-024-00425-w.
- [14] M. Lünich, B. Keller, y F. Marcinkowski, «Fairness of Academic Performance Prediction for the Distribution of Support Measures for Students: Differences in Perceived Fairness of Distributive Justice Norms», *Tech Know Learn*, vol. 29, n.º 2, pp. 1079-1107, jun. 2024, doi: 10.1007/s10758-023-09698-y.
- [15] S. P. Phokoye *et al.*, «Exploring the Adoption of Robotics in Teaching and Learning in Higher Education Institutions», *Informatics*, vol. 11, n.º 4, p. 91, nov. 2024, doi: 10.3390/informatics11040091.
- [16] M. Lünich y B. Keller, «Explainable Artificial Intelligence for Academic Performance Prediction. An Experimental Study on the Impact of Accuracy and Simplicity of Decision Trees on Causability and Fairness Perceptions», en *The 2024 ACM Conference on Fairness, Accountability, and Transparency*, Rio de Janeiro Brazil: ACM, jun. 2024, pp. 1031-1042. doi: 10.1145/3630106.3658953.
- [17] R. Kannan, M. Abarna, y S. Vairachilai, «Enhancing Student Academic Performance Forecasting in Technical Education: A Cutting-edge Hybrid Fusion Method», *SSRG-IJECE*, vol. 11, n.º 12, pp. 146-153, dic. 2024, doi: 10.14445/23488549/IJECE-V11I12P114.
- [18] Z. Dai, Y. Yuan, X. Zhu, y L. Zhao, «A Method for Predicting Indoor CO2 Concentration in University Classrooms: An RF-TPE-LSTM Approach», *Applied Sciences*, vol. 14, n.º 14, p. 6188, jul. 2024, doi: 10.3390/app14146188.
- [19] S. Wang y B. Luo, «Academic achievement prediction in higher education through interpretable modeling», *PLoS ONE*, vol. 19, n.º 9, p. e0309838, sep. 2024, doi: 10.1371/journal.pone.0309838.
- [20] H. Zhang, H. Wu, Z. Li, W. Gong, y Y. Yan, «Predicting the individual effects of team competition on college students' academic performance in mobile edge computing», *J Cloud Comp*, vol. 13, n.º 1, p. 38, feb. 2024, doi: 10.1186/s13677-024-00591-2.
- [21] E. Linares-Espinós *et al.*, «Metodología de una revisión sistemática», *Actas Urológicas Españolas*, vol. 42, n.º 8, pp. 499-506, oct. 2018, doi: 10.1016/j.acuro.2018.01.010.
- [22] C. Manterola, P. Astudillo, E. Arias, y N. Claros, «Revisiones sistemáticas de la literatura. Qué se debe saber acerca de ellas», *Cirugía Española*, vol. 91, n.º 3, pp. 149-155, mar. 2013, doi: 10.1016/j.ciresp.2011.07.009.
- [23] M. J. Page *et al.*, «Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas», *Revista Española de Cardiología*, vol. 74, n.º 9, pp. 790-799, sep. 2021, doi: 10.1016/j.recesp.2021.06.016.
- [24] M. J. Page y D. Moher, «Evaluations of the uptake and impact of the Preferred Reporting Items for Systematic reviews and Meta-Analyses (PRISMA) Statement and extensions: a scoping review», *Systematic Reviews*, vol. 6, n.º 1, p. 263, dic. 2017, doi: 10.1186/s13643-017-0663-8.
- [25] S. Briscoe, «Errors to avoid when searching for studies for systematic reviews: A guide for nurse researchers», *Int J Older People Nursing*, vol. 18, n.º 3, p. e12533, may 2023, doi: 10.1111/opn.12533.
- [26] G. Urrutia y X. Bonfill, «Declaración PRISMA: una propuesta para mejorar la publicación de revisiones sistemáticas y metaanálisis», *Medicina Clínica*, vol. 135, n.º 11, pp. 507-511, oct. 2010, doi: 10.1016/j.medcli.2010.01.015.
- [27] S. Abdulla, S. Ismail, Y. Fawzy, y A. Elhaj, «Using ChatGPT in Teaching Computer Programming and Studying its Impact on Students Performance», *Electron. J. e-Learning*, vol. 22, n.º 6, pp. 66-81, 2024, doi: 10.34190/EJEL.22.6.3380.
- [28] M. Almulla y S. I. Ali, «The Changing Educational Landscape for Sustainable Online Experiences: Implications of ChatGPT in Arab Students' Learning Experience», *Intl. J. Learn. Teach. Edu. Res.*, vol. 23, n.º 9, pp. 285-306, 2024, doi: 10.26803/ijlter.23.9.15.
- [29] M. A. Arbulú Ballesteros *et al.*, «The Sustainable Integration of AI in Higher Education: Analyzing ChatGPT Acceptance Factors Through an Extended UTAUT2 Framework in Peruvian Universities», *Sustainability*, vol. 16, n.º 23, 2024, doi: 10.3390/su162310707.
- [30] E. Orok *et al.*, «Pharmacy students' perception and knowledge of chat-based artificial intelligence tools at a Nigerian University», *BMC Med. Educ.*, vol. 24, n.º 1, 2024, doi: 10.1186/s12909-024-06255-8.
- [31] D. Playfoot, M. Quigley, y A. G. Thomas, «Hey ChatGPT, give me a title for a paper about degree apathy and student use of AI for assignment writing», *Internet Higher Educ.*, vol. 62, 2024, doi: 10.1016/j.iheduc.2024.100950.
- [32] B. Quah, L. Zheng, T. J. H. Sng, C. W. Yong, y I. Islam, «Reliability of ChatGPT in automated essay scoring for dental undergraduate examinations», *BMC Med. Educ.*, vol. 24, n.º 1, 2024, doi: 10.1186/s12909-024-05881-6.
- [33] R. Sandu, E. Gide, y M. Elkhodr, «The role and impact of ChatGPT in educational practices: insights from an Australian higher education case study», *Discov. Educ.*, vol. 3, n.º 1, 2024, doi: 10.1007/s44217-024-00126-6.
- [34] D. Smerdon, «AI in essay-based assessment: Student adoption, usage, and performance», *Comput. Educ.*, vol. 7, 2024, doi: 10.1016/j.caeai.2024.100288.
- [35] P. Vate-U-Lan y D. Cahill, «Advancing academic achievement: integrating society 5.0 and game-based learning in metaverse space for undergraduates in Bangkok, Thailand», *Cogent Educ.*, vol. 11, n.º 1, 2024, doi: 10.1080/2331186X.2024.2385239.
- [36] J. Wang *et al.*, «The impact of using ChatGPT on academic writing among medical undergraduates», *Ann. Med.*, vol. 56, n.º 1, 2024, doi: 10.1080/07853890.2024.2426760.
- [37] H. Yildiz Durak, «Impact of ML-LA feedback system on learners' academic performance, engagement and behavioral patterns in online collaborative learning environments: A lag sequential analysis and Markov chain approach», *Educ. Inf. Technol.*, 2024, doi: 10.1007/s10639-024-12911-9.
- [38] S. M. Mosleh, F. A. Alsaadi, F. K. Alnaqbi, M. A. Alkhzaimi, S. W. Alnaqbi, y W. M. Alsereidi, «Examining the association between emotional intelligence and chatbot utilization in education: A cross-sectional examination of undergraduate students in the UAE», *Heliyon*, vol. 10, n.º 11, 2024, doi: 10.1016/j.heliyon.2024.e31952.
- [39] J. Chen, S. Lau, J. Leinonen, V. Terragni, y N. Giacaman, «Detecting Learning Behavior in Programming Assignments by Analyzing Versioned Repositories», *IEEE Access*, vol. 12, pp. 188828-188844, 2024, doi: 10.1109/ACCESS.2024.3514843.
- [40] M. Eryilmaz y A. Adabashi, «Development of an intelligent tutoring system using bayesian networks and fuzzy logic for a higher student academic performance», *Appl. Sci.*, vol. 10, n.º 19, 2020, doi: 10.3390/AP10196638.
- [41] P. Taylor, «Blended Learning Challenges of EFL Undergraduate Students: Student Learning Experience in an AI-integrated ESP Course», *Stud. Engl. Lang. Edu.*, vol. 11, n.º 3, pp. 1231-1449, 2024, doi: 10.24815/siele.v11i3.37472.
- [42] D. Monteverde-Suárez *et al.*, «Predicting students' academic progress and related attributes in first-year medical students: an analysis with artificial neural networks and Naïve Bayes», *BMC Med. Educ.*, vol. 24, n.º 1, 2024, doi: 10.1186/s12909-023-04918-6.
- [43] A. Nabil, M. Seyam, y A. Abou-Elfetouh, «Prediction of Students' Academic Performance Based on Courses' Grades Using Deep Neural Networks», *IEEE Access*, vol. 9, pp. 140731-140746, 2021, doi: 10.1109/ACCESS.2021.3119596.

- [44] R. N. Rajamoni, R. M. S. Kumar, y B. C. Leela, «Factors Affecting the Academic Performance of Students with Hearing Impairments», *Rev. Intell. Artif.*, vol. 36, n.º 4, pp. 569-574, 2022, doi: 10.18280/ria.360408.
- [45] N. A. M. Samsudin, S. M. Shaharudin, N. A. F. Sulaiman, S. Ismail, N. S. Mohamed, y N. H. M. Husin, «Prediction of Student's Academic Performance during Online Learning Based on Regression in Support Vector Machine», *Int. J. Inf. Educ. Technol.*, vol. 12, n.º 12, pp. 1431-1435, 2022, doi: 10.18178/ijiet.2022.12.12.1768.
- [46] L. E. Contreras, H. J. Fuentes, y J. I. Rodriguez, «Academic performance prediction by machine learning as a success/failure indicator for engineering students», *Form. Univ.*, vol. 13, n.º 5, pp. 233-246, 2020, doi: 10.4067/S0718-50062020000500233.
- [47] J. Macedo y P. C. Oliveira, «Use of ICT to implement an active learning strategy in soil mechanics courses at undergraduate level», *Soils Rocks*, vol. 47, n.º 2, 2024, doi: 10.28927/SR.2024.007323.
- [48] T. Zhang, Z. Zhong, W. Mao, Z. Zhang, y Z. Li, «A New Machine-Learning-Driven Grade-Point Average Prediction Approach for College Students Incorporating Psychological Evaluations in the Post-COVID-19 Era», *Electronics (Switzerland)*, vol. 13, n.º 10, 2024, doi: 10.3390/electronics13101928.
- [49] C. Lu y M. Cutumisu, «Online engagement and performance on formative assessments mediate the relationship between attendance and course performance», *Int. j. educ. technol. high. educ.*, vol. 19, n.º 1, 2022, doi: 10.1186/s41239-021-00307-5.
- [50] I. López-Francés, F. J. García-García, B. G. López, y C. Molla-Esparza, «Implications of Message Length and Delay in Undergraduate Online Discussions», *RIED Rev. Iberoam. Educ. Distancia.*, vol. 25, n.º 2, pp. 259-276, 2022, doi: 10.5944/ried.25.2.32810.
- [51] S. El-Keiey, D. ElMenshawy, y E. Hassanein, «Student's Performance Prediction based on Personality Traits and Intelligence Quotient using Machine Learning», *Intl. J. Adv. Comput. Sci. Appl.*, vol. 13, n.º 9, pp. 292-299, 2022, doi: 10.14569/IJACSA.2022.0130934.
- [52] J. Gera, E. B. Marwaha, R. Thareja, y A. Jain, «Predicting and Improving Behavioural Factors that Boosts Learning Abilities in Post-Pandemic Times using AI Techniques», *Intl. J. Adv. Comput. Sci. Appl.*, vol. 14, n.º 11, pp. 274-282, 2023, doi: 10.14569/IJACSA.2023.0141127.
- [53] S. K. Ghosh, F. Janan, y I. Ahmad, «Application of the Classification Algorithms on the Prediction of Student's Academic Performance», *Trends Sci.*, vol. 19, n.º 14, 2022, doi: 10.48048/tis.2022.5070.
- [54] A. Gonzalez-Nucamendi, J. Noguez, L. Neri, V. Robledo-Rella, y R. M. G. García-Castelán, «Predictive analytics study to determine undergraduate students at risk of dropout», *Front. Educ.*, vol. 8, 2023, doi: 10.3389/educ.2023.1244686.
- [55] O. Herrera-Alcántara, A. Y. Barrera-Animas, M. González-Mendoza, y F. Castro-Espinoza, «Monitoring student activities with smartwatches: On the academic performance enhancements», *Sensors*, vol. 19, n.º 7, 2019, doi: 10.3390/s19071605.
- [56] D. Khairy, N. Alharbi, M. A. Amasha, M. F. Areed, S. Alkhalaf, y R. A. Abougalala, «Prediction of student exam performance using data mining classification algorithms», *Educ. Inf. Technol.*, vol. 29, n.º 16, pp. 21621-21645, 2024, doi: 10.1007/s10639-024-12619-w.
- [57] M. V. Martins, L. Baptista, J. Machado, y V. Realinho, «Multi-Class Phased Prediction of Academic Performance and Dropout in Higher Education», *Appl. Sci.*, vol. 13, n.º 8, 2023, doi: 10.3390/app13084702.
- [58] E. Muratov, M. Lewis, D. Fourches, A. Tropsha, y W. C. Cox, «Computer-assisted decision support for student admissions based on their predicted academic performance», *Am. J. Pharm. Educ.*, vol. 81, n.º 3, 2017, doi: 10.5688/ajpe81346.
- [59] R. Wei, «Examining the influence of the RIASEC theory within the Holland code on students' academic performance in their chosen disciplines among the context of higher education», *Cogent Educ.*, vol. 11, n.º 1, 2024, doi: 10.1080/2331186X.2024.2391274.
- [60] C. Zhang, J. Yang, M. Li, y M. Deng, «Simulation-Based Machine Learning for Predicting Academic Performance Using Big Data», *Int. J. Gaming Computer-Mediated Simul.*, vol. 16, n.º 1, 2024, doi: 10.4018/IJGMS.348052.
- [61] Z. Alamgir, H. Akram, S. Karim, y A. Wali, «Enhancing Student Performance Prediction via Educational Data Mining on Academic Data», *Informatics Educ.*, vol. 23, n.º 1, pp. 1-24, 2024, doi: 10.15388/infedu.2024.04.
- [62] E. Bolaños-Rodríguez, C. Flores-Amador, A. López-Chau, A. E. Solis-Galindo, y A. Zárate-Rosas, «PREDICTING ACADEMIC PERFORMANCE IN UNIVERSITY STUDENTS USING MACHINE LEARNING», *J. Eng. Technol. Ind. Appl.*, vol. 10, n.º 49, pp. 223-228, 2024, doi: 10.5935/jetia.v10i49.1308.
- [63] C.-H. Chen, S. J. H. Yang, J.-X. Weng, H. Ogata, y C.-Y. Su, «Predicting at-risk university students based on their e-book reading behaviours by using machine learning classifiers», *Australas. J. Educ. Technol.*, vol. 37, n.º 4, pp. 130-144, 2021, doi: 10.14742/ajet.6116.
- [64] J. R. Rico-Juan, C. Cachero, y H. Macià, «Study regarding the influence of a student's personality and an LMS usage profile on learning performance using machine learning techniques», *Appl. Intell.*, vol. 54, n.º 8, pp. 6175-6197, 2024, doi: 10.1007/s10489-024-05483-1.
- [65] A. E. Tatar y D. Düşteğör, «Prediction of academic performance at undergraduate graduation: Course grades or grade point average?», *Appl. Sci.*, vol. 10, n.º 14, 2020, doi: 10.3390/app10144967.
- [66] M. Yağcı, «Educational data mining: prediction of students' academic performance using machine learning algorithms», *Smart Learn. Environ.*, vol. 9, n.º 1, 2022, doi: 10.1186/s40561-022-00192-z.
- [67] H. B. Essel, D. Vlachopoulos, A. Tachie-Menson, E. E. Johnson, y P. K. Baah, «The impact of a virtual teaching assistant (chatbot) on students' learning in Ghanaian higher education», *Int. j. educ. technol. high. educ.*, vol. 19, n.º 1, 2022, doi: 10.1186/s41239-022-00362-6.
- [68] D. Hao, Y. Xiaoqi, y Q. Taoyu, «Hybrid Machine Learning Models Based on CATBoost Classifier for Assessing Students' Academic Performance», *Intl. J. Adv. Comput. Sci. Appl.*, vol. 15, n.º 7, pp. 94-106, 2024, doi: 10.14569/IJACSA.2024.0150709.
- [69] E. Solak y R. Cakır, «Exploring the effect of materials designed with augmented reality on language learners' vocabulary learning», *J. Educ. Online*, vol. 13, n.º 2, pp. 50-72, 2015, doi: 10.9743/jeo.2015.2.5.
- [70] K. Borhani y R. T. K. Wong, «An artificial neural network for exploring the relationship between learning activities and students' performance», *Decis. Anal. J.*, vol. 9, 2023, doi: 10.1016/j.dajour.2023.100332.
- [71] K. Sutherland *et al.*, «Non-traditional students' preferences for learning technologies and impacts on academic self-efficacy», *J. Comput. High. Educ.*, vol. 36, n.º 2, pp. 298-319, 2024, doi: 10.1007/s12528-023-09354-5.
- [72] S. Issaro y P. Wannapiroon, «Intelligent Student Relationship Management Platform with Machine Learning for Student Empowerment», *Int. J. Emerg. Technol. Learn.*, vol. 18, n.º 4, pp. 66-85, 2023, doi: 10.3991/ijet.v18i04.32583.
- [73] D. Di Giacomo, A. Martelli, F. Guerra, F. Cielo, y J. Ranieri, «Mediator effect of affinity for e-learning on mental health: Buffering strategy for the resilience of university students», *Int. J. Environ. Res. Public Health*, vol. 18, n.º 13, 2021, doi: 10.3390/ijerph18137098.
- [74] A. Nitchot, L. Gilbert, y W. Wettayaprasit, «Pedagogically-informed knowledge mapping: Representing contextualised competences and technology implemented», *Electron. J. e-Learning*, vol. 19, n.º 5, pp. 308-320, 2021, doi: 10.34190/ejel.19.5.2118.
- [75] M. V. T. Murillo, M. Lopez, M. C. M. Vergara, y J. M. Ramos, «Technology Inclusion as an Alternative Strategy for the Teaching of Anatomy», *J. High. Educ. Theory Pract.*, vol. 22, n.º 8, pp. 176-181, 2022, doi: 10.33423/jhetp.v22i8.5337.