

Evaluación de un modelo predictivo de Competencia Digital Docente usando técnicas de aprendizaje automático

Evaluation of a predictive model of Teachers' Digital Competence using Machine Learning techniques

Wiston Forero-Corba¹  , Francisca Negre-Bennasar²  , Francisco José Perales López³  

Doctor en Tecnología Educativa, Facultad de Educación, *Universitat de les Illes Balears* (UIB), Palma de Mallorca, España.¹
Doctora en Ciencias de la Educación, Facultad de Educación, *Universitat de les Illes Balears* (UIB), Palma de Mallorca, España.²
Doctor en Informática, Facultad Escuela Politécnica Superior, *Universitat de les Illes Balears* (UIB), Palma de Mallorca, España.³

ISSN 2619-2608

DOI: <https://doi.org/10.34069/RA/2026.17.04>

Cómo citar:

Forero-Corba, W., Negre-Bennasar, F., & Perales López, F.J. (2026). Evaluación de un modelo predictivo de Competencia Digital Docente usando técnicas de aprendizaje automático. *Revista Científica Del Amazonas*, 9(17), 43-63.
<https://doi.org/10.34069/RA/2026.17.04>

Recibido: 12 de enero de 2026

Aceptado: 20 de mayo de 2026



Resumen

La Competencia Digital Docente (CDD) se define como el conjunto de habilidades y destrezas digitales que los docentes aplican en los procesos de enseñanza-aprendizaje. El aprendizaje automático (ML), rama de la inteligencia artificial, emplea técnicas para identificar y predecir patrones en grandes volúmenes de datos. Los estudios sobre CDD resultan esenciales para las instituciones educativas, pues impactan en el desarrollo integral de los estudiantes y orientan a los directivos en la implementación de acciones de formación que fortalezcan las capacidades digitales de su planta docente. El objetivo de este trabajo es evaluar un modelo de predicción de la CDD considerando dimensiones pedagógicas, comunicativas, investigativas, tecnológicas y de gestión. La metodología adoptó un enfoque mixto, descriptivo y no experimental, sustentado en la Investigación Basada en Diseño. La muestra incluyó 128 docentes de una institución educativa en Bogotá y 53 docentes de 41 instituciones colombianas. Los resultados evidenciaron que el nivel de CDD es limitado en los docentes del país. Las conclusiones destacan la alta efectividad del uso de técnicas inteligentes para la predicción de la CDD y plantean propuestas que pueden orientar futuras investigaciones en el ámbito educativo.

Palabras clave: aprendizaje automático, competencia digital docente, evaluación, inteligencia artificial, tecnología educativa.

Abstract

Teachers' Digital Competence (TDC) is defined as the set of digital skills and competencies that teachers apply in teaching and learning processes. Machine learning (ML), a branch of artificial intelligence, uses techniques to identify and predict patterns in large volumes of data. Studies on TDC are essential for educational institutions, as they impact students' holistic development and guide administrators in implementing training initiatives that strengthen the digital capabilities of their teaching staff. The objective of this study is to evaluate a TDC prediction model considering pedagogical, communicative, research, technological, and management dimensions. The methodology adopted a mixed-methods, descriptive, and non-experimental approach, grounded in Design-Based Research. The sample included 128 teachers from an educational institution in Bogotá and 53 teachers from 41 Colombian institutions. The results showed that the level of TDC is limited among the country's teachers. The conclusions highlight the high effectiveness of using intelligent techniques to predict TDC and propose recommendations that can guide future research in the field of education.

Keywords: machine learning, teachers' digital competence, evaluation, artificial intelligence, educational technology.

Introducción

La Competencia Digital Docente (CDD) es una condición importante para la integración efectiva de las tecnologías en la educación (Cattaneo et al., 2022). Definimos la CDD como la comprensión, desarrollo y aplicación de conocimientos, aptitudes, habilidades y estrategias propias de los docentes acerca del amplio mundo digital existente mediante procesos de enseñanza-aprendizaje desde su práctica profesional. Según Cabero-Almenara, & Palacios-Rodríguez (2020), la aplicación efectiva de estas competencias permite a los docentes solucionar problemas y retos educativos presentes en la actual sociedad.

Aplicar la CDD a la praxis académica no solo requiere de una formación inicial de los sistemas digitales, con el avance tecnológico exponencial a su paso, requiere de una formación continua durante el ejercicio docente. No obstante, esta formación continua requiere en algunos momentos de recursos tecnológicos que en ocasiones las instituciones educativas no poseen y se convierte en una limitante no solo en los procesos de enseñanza, sino también en los procesos de actualización docente. Esteve et al. (2018) plantean el interrogante de cómo el docente utiliza la tecnología disponible para llevar a cabo su misión de la forma más idónea posible, afirmando que no se habla de una competencia digital genérica ya que depende del contexto educativo al que se enfrente.

A pesar de la existencia de estos marcos normativos y del reconocimiento de la importancia de la CDD, persiste una brecha metodológica y práctica en su evaluación. Tradicionalmente, la medición de la CDD se ha basado en instrumentos de autopercepción y encuestas estáticas que, si bien son útiles, pueden presentar sesgos de subjetividad y no escalan eficientemente ante grandes volúmenes de datos. En el contexto específico de Colombia, aunque se cuenta con el Marco de Competencias TIC (Ministerio de Educación Nacional, 2013), las instituciones carecen de herramientas predictivas automatizadas y basadas en datos empíricos que permitan diagnosticar de manera ágil y objetiva el nivel de sus docentes. Esta carencia de instrumentos de evaluación dinámicos e inteligentes dificulta la toma de decisiones oportunas y el diseño de planes de formación continua realmente adaptados a las falencias reales del profesorado.

Por consiguiente, la presente investigación se justifica desde tres dimensiones fundamentales. A nivel científico, el estudio aporta evidencia empírica sobre la eficacia comparativa de diferentes algoritmos de ML aplicados a la evaluación educativa, consolidando un área de conocimiento emergente en la intersección entre la inteligencia artificial y la pedagogía. A nivel pedagógico, la validación de un modelo predictivo robusto permitirá a las instituciones identificar de forma temprana y precisa las necesidades formativas de los docentes en sus cinco dimensiones (comunicativa, de gestión, investigativa, pedagógica y tecnológica), facilitando la creación de rutas de aprendizaje personalizadas. Finalmente, a nivel contextual, este trabajo ofrece una solución tecnológica innovadora y adaptada a la realidad colombiana, optimizando los recursos institucionales y promoviendo una cultura de evaluación continua que impacte directamente en la calidad de los procesos de enseñanza-aprendizaje.

En respuesta a esta problemática, el objetivo principal de este trabajo es evaluar un modelo de predicción de la CDD de los docentes colombianos con técnicas de ML. El modelo se basó en el Marco de competencias TIC para el desarrollo profesional docente colombiano que se centra en los aspectos pedagógicos, comunicativos, investigativos, tecnológicos y de gestión.

A partir de todo ello, se formulan las siguientes preguntas de investigación (PI):

PI1: ¿Cómo se relacionan las predicciones de la CDD obtenidas por cada técnica?

PI2: ¿Cuál de las técnicas de ML utilizadas en el modelo de predicción de CDD demostró mayor efectividad?

PI3: ¿Cuáles son las diferencias entre los resultados obtenidos del modelo de predicción de CDD en docentes de diferentes niveles educativos?

PI4: ¿Cómo varían los niveles de CDD entre docentes de distintas instituciones?

Marco Teórico o Revisión de literatura

Marcos de evaluación de la CDD

Los diferentes contextos educativos ante sus diversas necesidades han llevado a la creación y enriquecimiento de diferentes modelos y marcos de la evaluación de la CDD. No obstante, Durán et al. (2019) afirman que la competencia digital va mucho más allá de usar tecnologías digitales, haciendo énfasis en la importancia de variables o dimensiones necesarias en cualquier contexto como la investigación y la gestión.

España actualmente se reglamenta bajo el Marco Europeo de Competencia Digital del Profesorado DigCompEdu (Redecker, 2020), el cual es un marco de referencia europea que ayuda a visualizar no solo el nivel de CDD sino además del estudiante. El nivel de CDD está ampliamente relacionado con su formación académica y con el nivel educativo en el que enseña. Este marco a nivel internacional es altamente conocido pudiéndose aplicar en otros contextos educativos fuera de la Unión Europea.

Sin embargo, Latinoamérica por su parte, no tiene constituido un marco común de referencia, cada país o región maneja su propio marco, por ejemplo, en México se implementa la Agenda Digital Educativa (Secretaría de Educación Pública, 2020) que tiene como objetivo potencializar las tecnologías de información y comunicación (TIC) para mejorar y transformar el sistema educativo.

Asimismo, en Chile se aplica el marco de Competencias y Estándares TIC para la profesión docente en Chile (Ministerio de Educación, 2011), el cual define el nivel de la CDD a partir de las dimensiones técnica, pedagógica, de gestión, desarrollo y responsabilidad profesional, social, ética y legal.

Por otra parte, en Colombia se rige por el marco de Competencias TIC para el desarrollo profesional docente colombiano (Ministerio de Educación Nacional, 2013) donde la CDD comprende las dimensiones: comunicativa, de gestión, investigativa, pedagógica y tecnológica.

No obstante, existen propuestas de diseños de marcos que son globales y pueden ser aplicados en diferentes contextos como por ejemplo el Marco de competencias docentes en materia de TIC de la UNESCO (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura, 2019), un ejemplo claro es la investigación de González Fernández (2021) que aplica este marco de referencia en una investigación en docentes de México.

A pesar de las diferencias de los marcos, éstos suelen tener una misma finalidad y es generar alto impacto en los procesos significativos de enseñanza-aprendizaje, mejorando la calidad educativa a través de los resultados académicos de los estudiantes y el fortalecimiento de la profesión docente.

Inteligencia Artificial y Aprendizaje Automático en la evaluación de la CDD

García-Ruiz et al. (2023) plantean la necesidad de investigar mecanismos que ayuden a predecir y evaluar la CDD de manera fiable y efectiva. Es así como, gracias a tecnologías emergentes como el Big Data y campos de Inteligencia Artificial (IA) como el aprendizaje automático (ML, por sus siglas en inglés *Machine Learning*) o aprendizaje profundo (*Deep Learning*), nace la posibilidad de investigar e innovar en modelos para la predicción de la evaluación de la CDD (Forero-Corba & Negre Bennasar, 2024b).

El aprendizaje automático es una rama de la IA que genera predicciones de datos masivos usando diversas técnicas inteligentes (Tarik et al., 2021). Estudios previos han mostrado variables predictoras de los niveles de CDD, por ejemplo, Zhao (2024) construye un modelo de predicción de la CDD utilizando datos empíricos de docentes de secundaria en China. Por su parte, Cabero-Almenara et al. (2022) a partir de modelos de ecuaciones estructurales predijeron los niveles de CDD de los docentes universitarios en base al marco común DigCompEdu. Asimismo, Antonietti et al. (2022) usando modelos de ecuaciones estructurales, predicen la percepción y la actitud de los docentes frente a las tecnologías digitales (TD). Finalmente, Gómez et al. (2022) proponen la medición de niveles de CDD a partir de simulaciones virtuales.

Galindo-Domínguez et al. (2024) afirman que futuras intervenciones basadas en IA se deben aplicar para mejorar dimensiones clave de la CDD como la gestión de la información, la creación de contenidos digitales y la resolución de problemas en los procesos de enseñanza. A pesar de que la implementación de la IA puede ser lenta por procesos administrativos y políticos de cada país (Moreno Padilla, 2019), responder a esta realidad supone explorar el desarrollo de la CDD hacia una certificación auténtica de los docentes (Martín-Párraga et al., 2022).

Metodología

La investigación se realizó entre los años 2022 y 2025 con un enfoque mixto, descriptivo y no experimental. Este estudio está centrado en la Investigación Basada en Diseño (IBD) (De Benito & Salinas, 2016) ya que la implementación y evaluación de un entorno enriquecido con ML genera procesos educativos innovadores y soluciones reales ante las dinámicas de la práctica educativa actual. Para el análisis cuantitativo de la investigación utilizamos el *Software Orange Data Mining* versión 3.38.1 y el *Software IBM SPSS Statistics* versión 29, mientras que para el análisis cualitativo se analizó con el *Software NVIVO* versión 14.

Diseño de la Investigación

El diseño de la investigación (Figura 1) se basó en el modelo IBD apoyado por el modelo ADDIE (Esquivel Gámez, 2014), debido a que se caracteriza por la iteración de sus fases, evidenciando así un proceso continuo de revisión y reformulación del estudio.

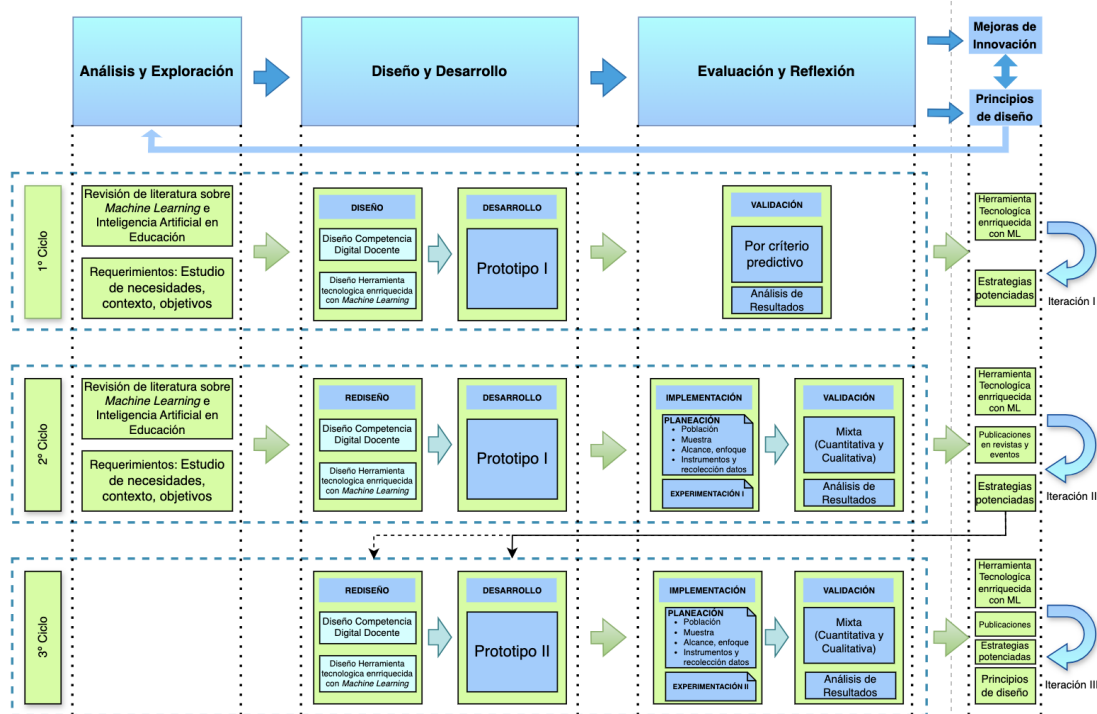


Figura 1. Modelo IBD tipo ADDIE aplicado en la investigación

Fuente: Adaptado del modelo IBD en De Benito & Salinas (2016) y modelo ADDIE en Esquivel Gámez (2014).

La siguiente Tabla 1 describe explícitamente como se implementó cada fase del modelo ADDIE dentro del estudio:

Tabla 1.
Descripción del modelo ADDIE dentro del Modelo IBD

Fase ADDIE	Modelo IBD	Actividades
Análisis	Análisis y Exploración	Revisión de literatura, estudio de necesidades, contexto y objetivos.
Diseño	Diseño y Desarrollo	Diseño de la CDD y de la herramienta enriquecida con Machine Learning.
Desarrollo	Diseño y Desarrollo	Creación del Prototipo I y posteriormente del Prototipo II.
Implementación	Evaluación y Reflexión	Aparece explícitamente en el 2º y 3º ciclo: Planeación y Experimentación I y II.
Evaluación	Evaluación y Reflexión	Validación por criterio predictivo, análisis de resultados y validación mixta.

Fuente: Elaboración propia.

Para garantizar la rigurosidad científica y la trazabilidad del estudio, el flujo metodológico se estructuró y ejecutó operativamente en tres ciclos iterativos de revisión y reformulación continua. El primer ciclo abarcó el análisis exploratorio de literatura, el levantamiento de requerimientos del contexto y estudio de necesidades; el segundo ciclo se centró en el diseño de la herramienta enriquecida con aprendizaje automático, el desarrollo del Prototipo I y su validación inicial por criterio predictivo; y el tercer ciclo consistió en el rediseño hacia el Prototipo II, su implementación en campo y la validación mixta de los resultados obtenidos.

La replicabilidad técnica del componente cuantitativo y cualitativo se asegura mediante la estandarización en la recolección y procesamiento de datos, detalladas en la sección *Técnicas e Instrumentos de recogida de información*.

Modelo enriquecido con técnicas de aprendizaje automático

El modelo aplicado en esta investigación fue el propuesto por Forero-Corba & Negre Bennisar (2024a) el cual es un modelo de predicción para la evaluación de la CDD usando técnicas de ML. Se aplica el *Software Orange Data Mining* versión 3.38.1 debido a su capacidad para integrar diversas técnicas de análisis de datos y aprendizaje automático en una interfaz visual intuitiva, lo que facilita la validación del modelo sin requerir conocimientos avanzados en programación (Caglayan, 2019), permitiendo así un enfoque más accesible y replicable en la investigación educativa.

Este modelo contempla el análisis de cinco competencias digitales esenciales para el docente colombiano: comunicativa, de gestión, investigativa, pedagógica y tecnológica.

Asimismo, el modelo contempla tres niveles progresivos de evaluación que facilitan la identificación del avance y la consolidación de las competencias en cada etapa del proceso formativo. Estos niveles se denominan: Explorador, Integrador e Innovador.

Población objetivo

La población de estudio estuvo confirmada por 186 docentes de una institución educativa de la Ciudad de Bogotá D.C, Colombia. La institución educativa (la cual llamaremos institución principal) es de carácter pública, bilingüe, laica y mixta. Se encuentra ubicada en la localidad 19 de Ciudad Bolívar, al sur de la ciudad y cuenta con aproximadamente 4000 estudiantes en los niveles de preescolar, primaria y secundaria.

Determinación de la muestra

La muestra total del estudio se estructuró en dos grupos con abordajes metodológicos complementarios. El primer grupo estuvo conformado por 128 docentes de la institución principal, quienes desempeñan sus labores en los niveles de preescolar, primaria y secundaria; este segmento fue analizado bajo un enfoque cuantitativo. En segundo lugar, con el objetivo de profundizar en los hallazgos, se evaluó a un grupo de 53 docentes pertenecientes a otras 41 instituciones educativas de diversas regiones de Colombia (denominadas en este estudio como otras instituciones).

Esta submuestra integra tanto entornos urbanos como rurales y abarca todos los niveles de enseñanza preescolar, primaria y secundaria. Dado que este segundo grupo no posee representatividad estadística a nivel poblacional, sus resultados se abordaron mediante un análisis cualitativo.

Para los 128 docentes de la institución principal, se realizó un muestreo probabilístico aleatorio simple debido a que reduce el sesgo de selección, posibilita hacer generalizaciones sobre la población y estimar el error con un cierto grado de confianza (Ahmed, 2024).

Se calculó la muestra mediante las fórmulas para muestras finitas: (1) fórmula de Cochran y (2) fórmula de Yamane, tal como se especifican en la Tabla 2.

Tabla 2.
Fórmulas para muestras finitas

Fórmula de Cochran	Fórmula de Yamane
$n = N \frac{[Z_{\alpha}^2 pq]}{e^2(N - 1) + Z_{\alpha}^2 pq}$	$n = \frac{N}{1 + Ne^2}$

Fuente: Elaboración propia.

Donde:

- n = Tamaño de la muestra
- N = Tamaño de la población
- Z_{α} = Nivel de confianza
- e = Error de estimación máximo aceptado
- p = Probabilidad de que ocurra el evento estudiado
- $q = (1 - p)$ = Probabilidad de que no ocurra el evento estudiado

Para determinar la muestra, usamos: $N = 186$ que es la población objetivo, $Z_{\alpha} = 1,96$ con nivel de confianza del 95%, $e=5\%$ como error de estimación máximo aceptado, mientras que $p = 0.5$ y $q = 0.5$ ya que no tenemos investigaciones previas con la misma población objetivo sobre CDD, por ello se le da el mismo peso.

Finalmente, el cálculo del tamaño de la muestra n es:

- Fórmula Cochran: $n = 125,54 \approx 126$
- Fórmula Yamane: $n = 126,96 \approx 127$

Con base en cuenta los resultados anteriores, la muestra con la fórmula de Cochran comparada con la fórmula de Yamane son casi iguales, lo que confirma que nuestra investigación tuvo que usar una muestra mínima de 126 participantes para que se cumpliera el grado de confianza. La Figura 2 muestra el número de participantes seleccionados por nivel educativo.




Figura 2. Número de participantes seleccionados por nivel educativo.

Fuente: Elaboración propia.

Técnicas e Instrumentos de recogida de información

El modelo de predicción docente seleccionado plantea como instrumento de recogida de información una rúbrica de evaluación ya validada de 25 ítems. Esta rúbrica se aplicó, ya que sirve para medir y evaluar la CDD del docente colombiano en cualquier nivel educativo.

Las variables de este estudio se estructuraron a partir de una rúbrica de evaluación validada (Mantilla Contreras, 2022) compuesta por 25 ítems. Esta rúbrica se aplicó, ya que sirve para medir y evaluar el desempeño docente en cinco dimensiones fundamentales del marco colombiano: comunicativa, de gestión, investigativa, pedagógica y tecnológica para el docente colombiano en cualquier nivel educativo. La aplicación de las respuestas del cuestionario estuvo dada de forma digital utilizando el formulario *Google Forms*.

La codificación de los datos se realizó en dos niveles: para las variables de entrada (descriptores), se empleó una escala numérica del 1 al 4, donde cada valor corresponde a los niveles de progresión N1 (Principiante), N2 (Medio), N3 (Experto) y N4 (Transformador). Por otro lado, la variable objetivo (el nivel de CDD) se codificó de forma categórica para clasificar a los docentes en los niveles Explorador, Integrador o Innovador.

En cuanto al procesamiento operativo de información, los datos recolectados mediante *Google Forms* se consolidaron en archivos de formato *.csv* para su tratamiento en el software *Orange Data Mining* versión 3.38.1. El flujo de análisis incluyó el uso del widget *Feature Statistics* para determinar características estadísticas como la media \bar{X} , la moda \hat{X} y la dispersión S^2 de las variables, mientras que las proyecciones visuales de los patrones de datos se generaron mediante el widget *Scatter Plot*. Para asegurar la validez técnica externa de las predicciones y mitigar el riesgo de sobreajuste (*overfitting*), se aplicó un método de validación cruzada (*cross-validation* en inglés, método muy conocida en el campo de la IA para validar modelos) con particiones de ($k = 3$) y ($k = 10$). Posteriormente, el rendimiento de las nueve técnicas de aprendizaje automático supervisado se evaluó y cuantificó a través del Área Bajo la Curva (AUC por sus siglas en inglés *Area Under the ROC Curve*), que sirve como medio de comparación entre modelos de clasificación. Estos valores se obtuvieron usando el widget *Test and Score* de *Orange Data Mining*. Finalmente, Para medir el rendimiento de las técnicas por cada nivel de CDD, se utilizó el widget *Confusion Matrix* con partición de ($k = 10$), también de *Orange Data Mining*.

Para la recolección de información en ambos grupos, se utilizó una rúbrica de evaluación administrada a través de la plataforma *Google Forms*. En el caso específico de las "otras instituciones", y dado que este grupo no posee representatividad estadística a nivel poblacional, los datos se sometieron a un análisis cualitativo. Para ello, se empleó la técnica de codificación jerárquica, utilizando como herramienta de soporte el *software NVIVO* en su versión 14, lo que permitió una exploración detallada de las dimensiones de la CDD en diversos contextos geográficos del país.



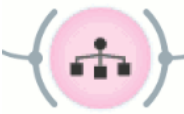
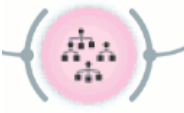




También se resalta la importancia de estimar las diferencias significativas de la CDD entre los docentes de zonas urbanas y rurales de las otras instituciones, para ello, utilizamos el *Software IBM SPSS Statistics* versión 29.

Técnicas de aprendizaje automático

El modelo predictivo propuesto se aborda como un problema de clasificación supervisada, dado que el objetivo es asignar a cada docente una etiqueta categórica predefinida (Explorador, Integrador o Innovador) basada en sus respuestas empíricas. Para garantizar una evaluación exhaustiva del rendimiento algorítmico, este modelo utiliza nueve técnicas de ML, todas ellas en el conjunto de aprendizaje supervisado ya que las predicciones se realizan a partir de datos etiquetados (Segura et al., 2022). Esta diversidad metodológica permite mitigar los sesgos individuales de cada algoritmo y determinar empíricamente el comportamiento de cada técnica de ML aplicada en las competencias digitales en el contexto del docente colombiano.

La Tabla 3 representa la técnica ML utilizada, seguida de su nombre y por último su definición.

Tabla 3.
Técnicas de aprendizaje automático utilizadas en el modelo

N	Abreviatura	Técnica
1	kNN	 kNN
2	LR	 Logistic Regression
3	DS	 Tree
4	RF	 Random Forest
5	NB	 Naive Bayes
6	GB	 Gradient Boosting
7	SVM	 SVM
8	SGD	 Stochastic Gradient Descent
9	NN	 Neural Network

Fuente: Basado y adaptado de Forero-Corba y Negre Bennasar (2024a, p. 24).

Consideraciones éticas

La presente investigación estuvo dada bajo la Ley 1581 de 2012 (Departamento Administrativo de la Función Pública, 2012) por la cual se dictan las disposiciones generales para la protección de datos personales en territorio colombiano. Los datos recopilados se utilizaron única y exclusivamente para temas académicos e investigativos.

Resultados y discusión

A continuación, se presentan los hallazgos empíricos derivados de la implementación del modelo predictivo para evaluar la CDD utilizando técnicas de ML. Estos resultados se estructuran y discuten secuencialmente para dar respuesta directa a las cuatro preguntas de investigación planteadas.

PI1: ¿Cómo se relacionan las predicciones de la CDD obtenidas por cada técnica?

En esta pregunta de investigación, con la Figura 3 y las Tablas 4 y 5, se desea conocer cómo se relacionan las predicciones de la CDD obtenidas por cada técnica.

La Figura 3 muestra de forma gráfica la predicción de la CDD para cada técnica.

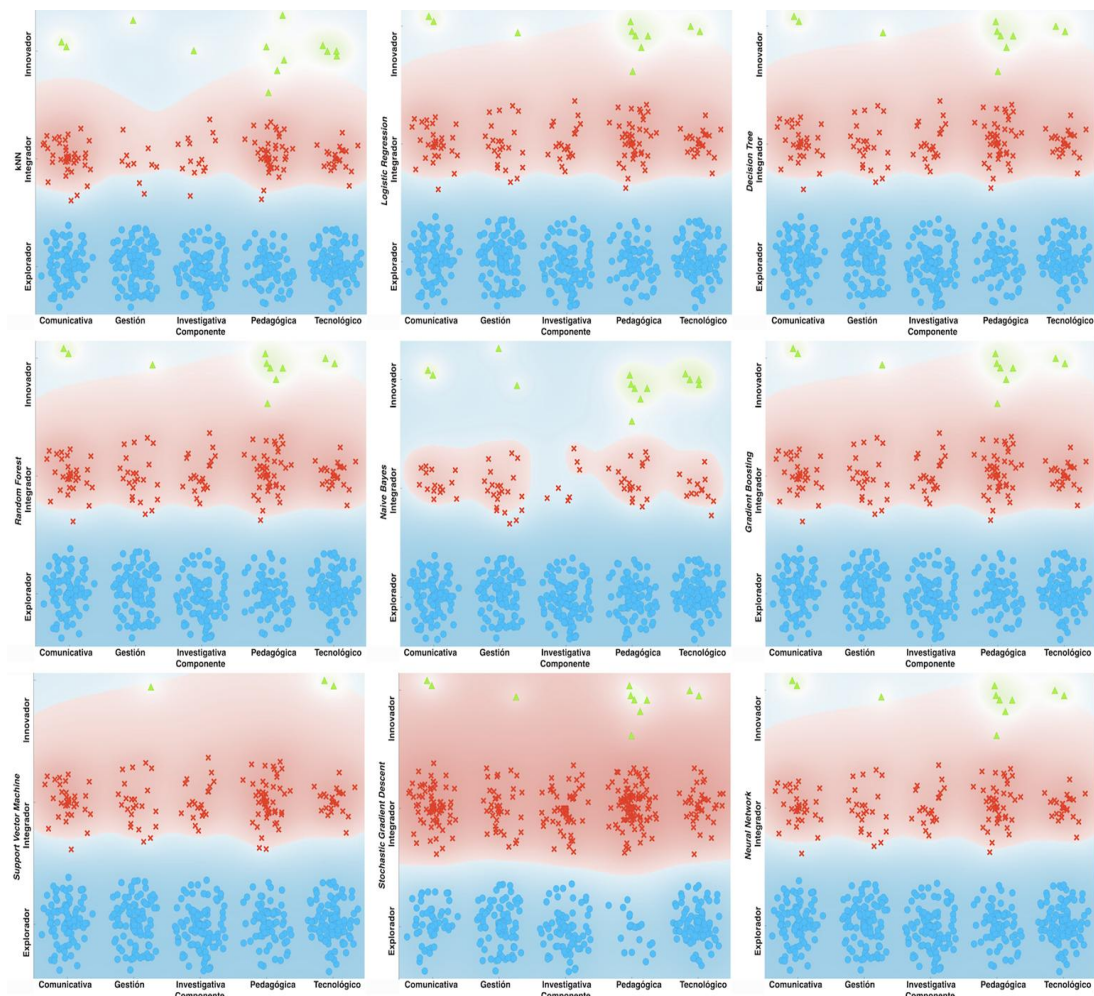


Figura 3. Gráficas de predicción de la CDD con técnicas ML

Fuente: Elaboración propia.

Nota: Símbolos niveles de CDD: Explorador ●, Integrador ×, Innovador ▲

En las nueve gráficas de la Figura 3, se observa una concentración densa de instancias en la zona inferior (azul), correspondiente al nivel Explorador, con una dispersión mínima hacia los niveles superiores en casi todas las técnicas. Los patrones de separación entre clases muestran fronteras nítidas entre Explorador e Integrador, pero poca presencia (puntos aislados) en el nivel Innovador.

La Tabla 4 muestra las características estadísticas para cada técnica. Las características están definidas como \bar{X} (media), \hat{X} (moda) y S^2 (dispersión).

Tabla 4.
Características estadísticas de las técnicas ML








N	Técnica ML	$\bar{X}_{Explorador}$	$\bar{X}_{Integrador}$	$\bar{X}_{Innovador}$	\hat{X}	S^2
1	kNN	0.770	0.211	0.020	Explorador	0.603
2	LR	0.748	0.234	0.017	Explorador	0.619
3	DT	0.755	0.228	0.017	Explorador	0.619
4	RF	0.751	0.231	0.017	Explorador	0.619
5	NB	0.707	0.725	0.018	Explorador	0.470
6	GB	0.755	0.228	0.171	Explorador	0.619
7	SVM	0.749	0.246	0.246	Explorador	0.580
8	SGD	0.580	0.409	0.010	Explorador	0.759
9	NN	0.755	0.228	0.017	Explorador	0.619

Fuente: Elaboración propia.

En la Tabla 4 se evidencia cómo la mayor parte de los docentes están en promedio ubicados en el nivel Explorador, que se evidencia también de forma gráfica en la Figura 3, lo que requiere un alto compromiso en los procesos de capacitación y actualización docente por parte de directivos. Ser consciente que la autonomía juega un papel importante en el desarrollo de habilidades digitales, como corrobora el estudio de Instefjord y Munthe (2017) en Noruega, el desarrollo de las competencias digitales docentes depende en gran medida de la iniciativa y el esfuerzo individual de cada profesor.

La Tabla 5 muestra la distribución gráfica de los niveles de los descriptores según rúbrica seleccionada: Nivel Principiante (N1), Nivel Medio (N2), Nivel Experto (N3) y Nivel Transformador (N4). También muestra las características estadísticas para los descriptores usados en la rúbrica. Las características están definidas como \bar{X} (media) y S^2 (dispersión).

Tabla 5.
Distribución de los descriptores

Descriptores	Distribución (N1, N2, N3, N4)	$\bar{X}_{descriptor}$	S^2
Descriptor 1		1.75	0.43
Descriptor 2		1.65	0.43
Descriptor 3		1.68	0.42
Descriptor 4		1.66	0.44
Descriptor 5		1.66	0.43
Descriptor 6		1.71	0.43
Descriptor 7		1.65	0.44

Fuente: Elaboración propia.

En la Tabla 5 se evidencia la distribución de las respuestas de los docentes por cada descriptor, evidenciando que la autopercepción de los docentes de la institución principal frente a lo evaluado en la rúbrica se ubicó, en su gran mayoría, entre los niveles N1 y N2. La Figura 7 confirma de forma cualitativa que la distribución de competencias también se organiza, mayoritariamente, entre los niveles N1 y N2.

PI2: ¿Cuál de las técnicas de ML utilizadas en el modelo de predicción de CDD demostró mayor efectividad?

En esta pregunta de investigación, se desea identificar la técnica más eficiente para calcular el rendimiento promedio final entre todas las evaluadas.

La Tabla 6 muestra el cálculo del AUC validación cruzada por con $k = 3$ y $k = 10$, donde k es el número de particiones iguales en las que se divide el conjunto de datos de entrenamiento.

Tabla 6.
Rendimiento de las técnicas ML

N	Técnica ML	AUC ($k = 3$)	AUC ($k = 10$)
1	GB	1.000	1.000
2	DS	0.956	1.000
3	LR	0.796	0.999
4	SVM	0.560	0.971
5	RF	0.399	0.999
6	SGD	0.256	0.869
7	NN	0.372	0.999
8	kNN	0.277	0.626
9	NB	0.099	0.809
	Promedio	0.524	0.919

Fuente: Elaboración propia.

La Tabla 7 muestra el cálculo del AUC con validación cruzada $k = 10$, donde k es el número de particiones iguales en las que se divide el conjunto de datos de entrenamiento.

Tabla 7.
Rendimiento de las técnicas ML por nivel de CDD con ($k = 10$)

N	Técnica ML	Explorador	Integrador	Innovador
1	GB	100%	100%	100%
2	DS	100%	100%	100%
3	LR	100%	100%	99%
4	SVM	100%	99.1%	96.9%
5	RF	100%	100%	99.9%
6	SGD	100%	94.1%	99.9%
7	NN	100%	100%	99.9%
8	kNN	69.6%	88.3%	76.3%
9	NB	92.9%	100%	64.3%
	Promedio	95.8%	97.9%	92.9%

Fuente: Elaboración propia.

PI3: ¿Cuáles son las diferencias entre los resultados obtenidos del modelo de predicción de CDD en docentes de diferentes niveles educativos?

En esta pregunta de investigación, con la Figura 4 se desea conocer a nivel las diferencias entre los resultados obtenidos del modelo de predicción de CDD en docentes de diferentes niveles educativos.

La Figura 4 muestra de forma gráfica los resultados de la predicción de la CDD utilizando la técnica de GB (mejor técnica de predicción según la Tabla 6) para los niveles educativos de preescolar, primaria y secundaria.




Figura 4. Gráficas de predicción de la CDD para preescolar, primaria y secundaria.

Fuente: Elaboración propia.

Nota: Símbolos niveles de CDD: Explorador ●. Integrador ✕. Innovador ▲

En la Figura 4, el patrón revela que en preescolar la concentración en el nivel base es más homogénea y compacta, sugiriendo una brecha más marcada frente al nivel Innovador que en secundaria.

La Figura 4 establece la necesidad de implementar acciones que fortalezca la CDD ya que en los tres niveles educativos (preescolar, primaria y secundaria) se evidencia escasas de habilidades digitales en el nivel innovador, especialmente en preescolar.

PI4: ¿Cómo varían los niveles de CDD entre docentes de distintas instituciones?

En esta pregunta de investigación, con las Figuras 5, 6, 7 y 8 y la Tabla 8, se desea presentar el comportamiento y variación de los niveles de CDD entre docentes de distintas instituciones.

La Figura 5 muestra el diagrama de exploración obtenido a partir de las respuestas dadas por los docentes. En ella se observa las principales temáticas analizadas de los resultados obtenidos de forma cualitativa.

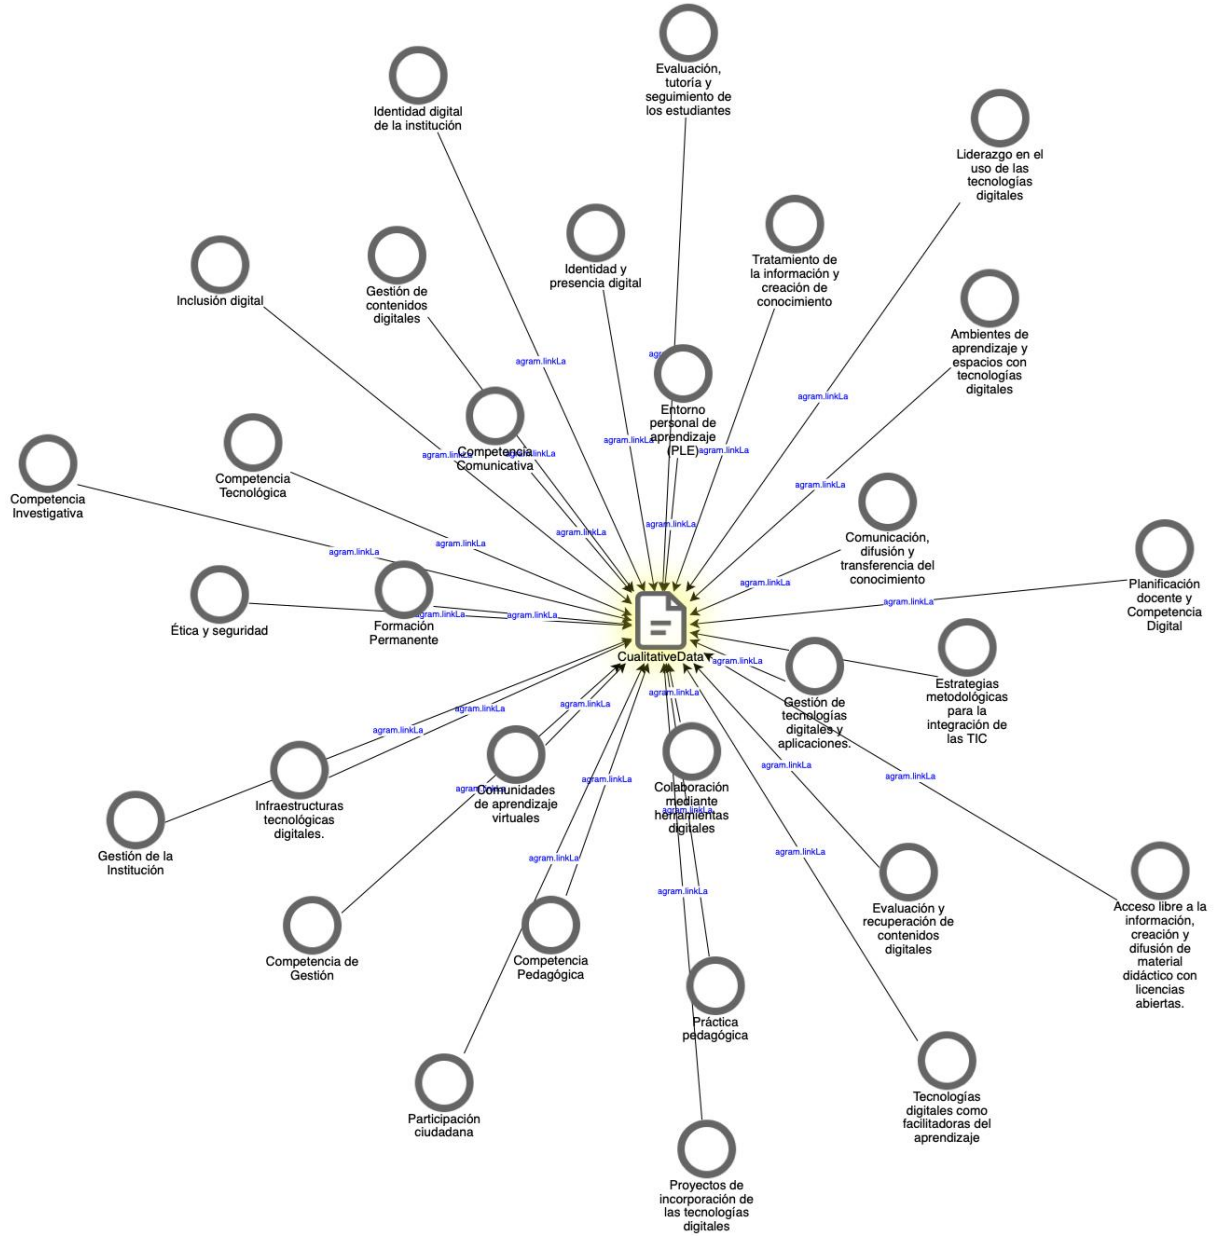


Figura 5. Diagrama de exploración
Fuente: Elaboración propia.

La Figura 6 muestra el diagrama jerárquico obtenido a partir de las respuestas dadas por los 128 docentes de la institución principal.

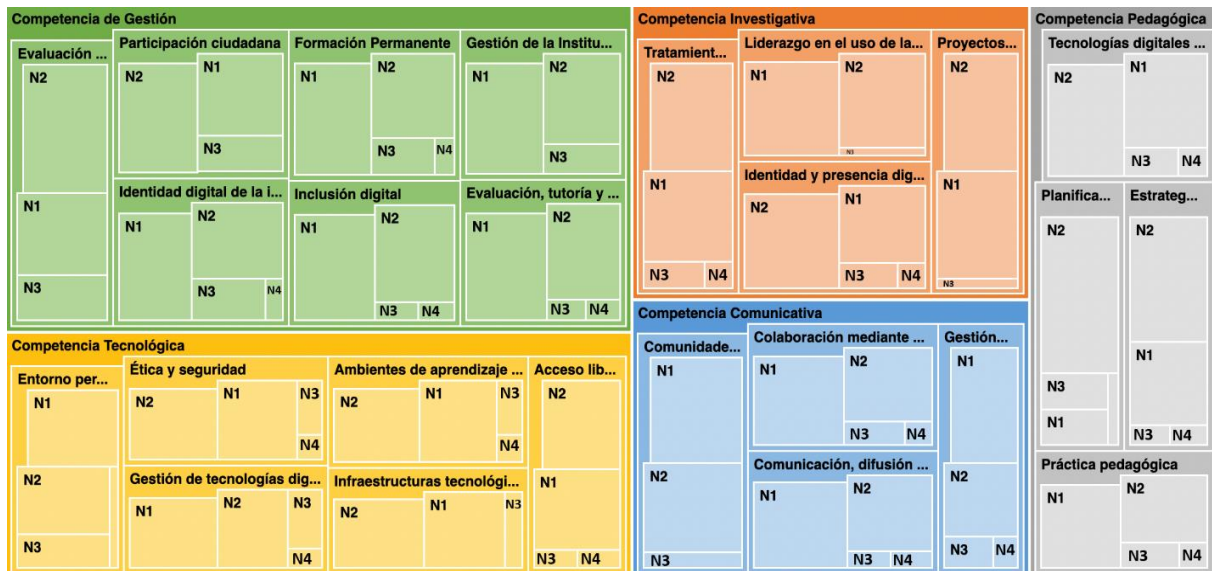


Figura 6. Diagrama jerárquico para los docentes de la institución principal
Fuente: Elaboración propia.

La Figura 7 muestra el diagrama jerárquico obtenido a partir de las respuestas dadas por los docentes de otras instituciones.

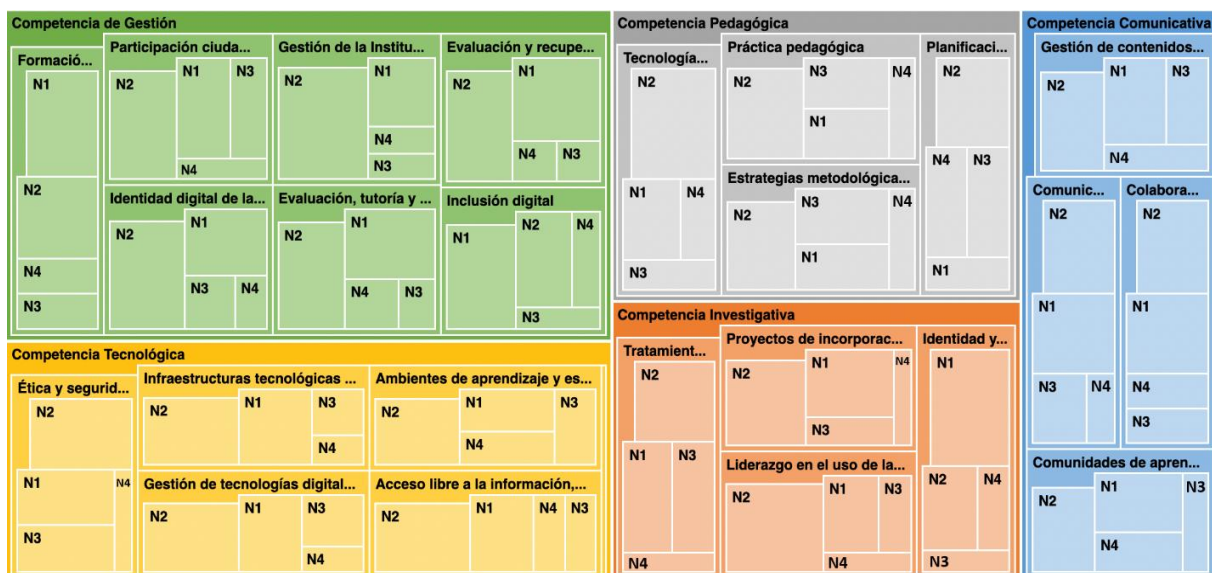


Figura 7. Diagrama jerárquico para los docentes de otras instituciones
Fuente: Elaboración propia.

Los diagramas jerárquicos de las Figuras 6 y 7, muestran una tendencia de autopercepción más elevada en docentes de otras instituciones, con una ramificación más extensa hacia niveles expertos (N3 y N4) en comparación con la institución principal, donde el patrón se concentra en niveles iniciales.

La Figura 8 muestra de forma gráfica los resultados de la predicción de la CDD de la Institución principal vs. Otras instituciones, utilizando la técnica de *Gradiente Boosting* GB (mejor técnica de predicción según la Tabla 6).

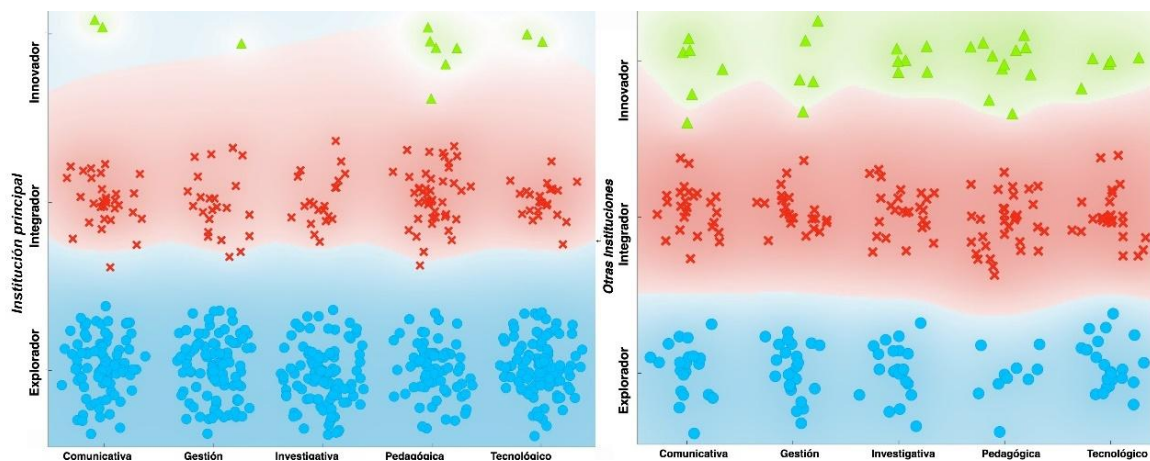


Figura 8. Gráficas de predicción de la CDD de la Institución principal vs. Otras Instituciones.
Fuente: Elaboración propia.

En la Figura 8, se observa un patrón de dispersión notablemente distinto entre ambos grupos analizados. Mientras que en la institución principal los datos se agrupan de forma densa en la franja inferior (color azul), revelando que la gran mayoría de los docentes se sitúan en el nivel Explorador, en las otras instituciones se aprecia una migración de los puntos hacia las franjas superiores (colores rojo y verde). Este patrón indica una mayor presencia de instancias en el nivel Innovador fuera de la institución base, donde los resultados de predicción son comparativamente más bajos.

La relación entre la Figura 6 y la Figura 7, muestra de forma cualitativa que los docentes de otras instituciones tienen mejor autopercepción en sus habilidades digitales ya que hay mayor presencia de niveles N3 y N4, especialmente en competencias tecnológicas y de gestión. Esta idea se apoya considerablemente con la gráfica de la Figura 8, donde se observa que los resultados de la predicción de la CDD de la institución principal son bajos con respecto a las otras instituciones, ya que hay mayor concentración de instancias en el nivel innovador. Este hallazgo sugiere una intervención inmediata en la mejora de la autopercepción de los docentes de la institución principal frente a sus competencias digitales, especialmente en competencias comunicativas, pedagógicas y de investigación.

La Tabla 8 presenta los resultados estadísticos de 53 docentes encuestados, pertenecientes a 41 instituciones educativas clasificadas como urbanas o rurales.

Tabla 8.
Estadísticas de grupo

Competencia	Grupo	N	Media	Desviación estándar	Desviación error promedio	$\alpha = Sig$
Pedagógica	Urbano	27	2.2870	.76806	.14781	.088
	Rural	26	2.3942	.61308	.12023	
Tecnológica	Urbano	27	2.1356	.58848	.11325	.966
	Rural	26	2.1212	.61082	.11979	
Comunicativa	Urbano	27	2.1204	.63689	.12257	.158
	Rural	26	2.1635	.76466	.14996	
Gestión	Urbano	27	2.0793	.66521	.12802	.541
	Rural	26	1.9619	.57264	.11230	
Investigativa	Urbano	27	2.0833	.72058	.13868	.654
	Rural	26	2.0096	.63828	.12518	

Fuente: Elaboración propia.

La Tabla 8 compara las medias de las otras instituciones educativas de zonas urbanas y rurales. En este análisis, el ámbito urbano demuestra un mejor desempeño en las competencias tecnológica, de gestión e investigación, mientras

que el ámbito rural sobresale en las competencias pedagógica y comunicativa. No obstante, es importante señalar que estas diferencias no alcanzan significancia estadística en ninguna de las competencias ya que $\alpha > .05$

En esta investigación se realizó un estudio de caso real donde se predijo a partir de nueve técnicas de ML, la CDD de un centro educativo. Los resultados muestran que se puede predecir la CDD con alta efectividad tal como se evidencia en la Tabla 6, donde el rendimiento promedio de las nueve técnicas es del 91.9%. No obstante, para profundizar en el desempeño real del modelo, se analizó en la Tabla 7, la precisión y sensibilidad por cada nivel de CDD de forma individual. Los resultados indican que el nivel Explorado obtuvo un rendimiento del 95.8%, el nivel Integrador de 97.9% y el nivel Innovador de 92.9%. Esta consistencia en las métricas transversales demuestra que el sistema identifica con similar rigor tanto a los niveles de CDD con mayor presencia de instancias como a los minoritarios, validando la robustez de las técnicas seleccionadas para la predicción de la CDD.

Investigaciones previas evidencian la alta efectividad de aplicar técnicas inteligentes, como es el caso de Hounque et al. (2022) donde evaluó con técnicas de ML el rendimiento académico en un 99% o de Misol Gerlache et al. (2022) donde se predijo situaciones educativas con una precisión superior al 96%. Esto demuestra que los resultados suman de manera significativa a investigaciones relacionadas sobre una comprensión más detallada y profunda del análisis de la CDD o técnicas de ML.

Además, esta investigación implementa nueve técnicas de ML, significativamente más que otras investigaciones, por ejemplo, la investigación Caglayan (2019) implementa tan solo tres técnicas y la investigación Yamamoto & Alverson (2022) aplica solo dos. Esto permite obtener resultados más precisos, adaptables y generalizables a diferentes contextos educativos.

En comparación con (Zhao, 2024), el estudio presenta diferencias relevantes en la muestra ya que el contexto y los instrumentos utilizados son diferentes; mientras Zhao analiza docentes de secundaria en China con variables centradas en la brecha digital, esta investigación se enfoca en docentes colombianos de distintos niveles educativos y utiliza una rúbrica de autopercepción alineada con el marco nacional de CDD (Ministerio de Educación Nacional, 2013), lo que introduce particularidades culturales y metodológicas que limitan la comparabilidad directa de resultados.

En contraste con los anteriores estudios previos mencionados, que reportan altas tasas de efectividad de modelos de aprendizaje automático en contextos educativos, los resultados obtenidos en esta investigación requieren una interpretación más crítica ya que el mejor desempeño de técnicas como GB, DT y LR puede explicarse no solo por su capacidad para modelar relaciones no lineales o manejar interacciones entre variables, sino también por la estructura específica del conjunto de datos, caracterizado por una distribución concentrada en el nivel Explorador y posibles patrones redundantes derivados del instrumento. En este sentido, es necesario reconocer que la rúbrica utilizada, basada en autopercepción, actúa como fuente de etiquetas, lo cual puede introducir sesgos cognitivos como sobreestimación o subestimación de habilidades y afectar tanto la calidad de los datos como la capacidad real de generalización del modelo.

Los valores elevados de AUC obtenidos, en algunos casos cercanos a 1.000, deben interpretarse con cautela. Este comportamiento puede estar influenciado por la estructura del conjunto de datos, derivado de una rúbrica estandarizada que genera patrones consistentes entre variables, así como por la posible concentración de instancias en determinados niveles de la CDD. Si bien la validación cruzada aplicada mitiga parcialmente el riesgo de sobreajuste, se reconoce la necesidad de validar el modelo en con variables adicionales ya sean contextuales, sociodemográficas, a nivel de trayectoria docente real certificada, etc., para confirmar su estabilidad, capacidad de generalización y aplicabilidad en otros contextos educativos.

Tras responder las cuatro preguntas de investigación PI1, PI2, PI3 y PI4, se evidencia que las técnicas inteligentes no solo permiten realizar predicciones sobre la CDD, sino que también aportan beneficios adicionales que trascienden el análisis directo de los resultados. Estos beneficios, aunque indirectos, representan un valor significativo para futuras investigaciones en el ámbito educativo, especialmente cuando se trabaja con grandes volúmenes de datos y se busca optimizar la toma de decisiones. En este sentido, la Tabla 9 sintetiza doce beneficios potenciales derivados de la implementación de técnicas inteligentes en educación, los cuales refuerzan la pertinencia de su aplicación y abren

nuevas oportunidades para el desarrollo de modelos predictivos más robustos y aplicables en diversos contextos académicos.

Tabla 9.
Beneficios de las técnicas inteligentes en Educación

N	Beneficio	Justificación	Tomado de
1	Rendimiento académico	A partir de modelos de IA se puede evaluar eficazmente el rendimiento académico del estudiante.	(Baashar et al., 2022)
2	Personalización del aprendizaje	Una herramienta con técnicas inteligentes permite facilitar la selección del itinerario académico de las instituciones educativas para garantizar el rendimiento de los estudiantes.	(Houngue et al., 2022)
3	Deserción Escolar	La detección del abandono no sólo funciona con las variables de inscripción, sino que mejora después de los resultados del primer semestre. Técnicas de aprendizaje automático obtiene los mejores resultados.	(Segura et al., 2022)
4	Diseño Currículo	Las unidades didácticas han sido diseñadas y mejoradas desde una perspectiva práctica de la IA, aumentando su fiabilidad y aplicabilidad como apoyo docente.	(Bellas et al., 2022)
5	Alfabetización Digital	La alfabetización digital con técnicas IA refleja la nueva brecha digital de la competencia TIC de los docentes.	(Zhao, 2024)
6	Retroalimentación	Las aplicaciones novedosas pueden proporcionar apoyo para realizar un seguimiento y recopilar datos, evaluar el rendimiento y proporcionar una retroalimentación significativa al alumno.	(Bacos, 2020)
7	Robótica social	Identificación continua de las funciones y comportamiento de los robots sociales en el aula de clase.	(Ceha et al., 2022)
8	Escalabilidad	El análisis de datos mediante virtualización reduce el coste de la infraestructura e introduce mayor seguridad, movilidad, escalabilidad, agilidad y alta disponibilidad.	(Rahman Alzoubaidi et al., 2021)
9	Orientación profesional	Recomendación con técnicas de aprendizaje automático a los alumnos que acaban de obtener su GCSE a seleccionar su campo de estudio.	(Houngue et al., 2022)
10	Habilidades del siglo XXI	Los retos de la IA son predictores significativos de la adquisición de habilidades del siglo XXI	(Segbenya et al., 2023)
11	STEM	El análisis de datos está transformando las disciplinas STEM y juega un papel crucial en impulsar la participación de las mujeres en carreras tecnológicas.	(Cheng et al., 2021)
12	Objetivos de Desarrollo Sostenible	Modelos IA como componentes fundamentales para el cumplimiento de objetivos y desarrollo sostenible de las Naciones Unidas.	(Haleem et al., 2022)

Fuente: Elaboración propia.

Conclusiones

El estudio realizado en el centro educativo evidenció que la predicción de la CDD mediante nueve técnicas de ML alcanzó una alta efectividad, con un promedio del 91,9%.

La investigación sobre CDD es importante para las instituciones, ya que de su evaluación dependen el aprendizaje, trayectoria, dirección y comportamiento de los alumnos. Este estudio sobre CDD es fundamental para las instituciones educativas ya que no solo impacta en el desarrollo integral de los estudiantes, sino que también guía a los directivos docentes en la implementación de acciones concretas para capacitar su planta docente y elevar el nivel de CDD.

Las instituciones educativas, tanto los docentes como los directivos docentes deben estar preparados para adaptar la tecnología a sus prácticas educativas y así facilitar la identificación de necesidades formativas sobre CDD.

El potencial que tienen las técnicas inteligentes y en especial, las técnicas con ML para realizar esta tarea respecto a

la CDD, resulta fundamental como paso estratégico hacia la reducción de la brecha digital y escolar, la cual, durante los últimos años, ha sido un reto para los expertos del sector educativo en cualquier nivel escolar.

Diferentes tipos de rúbricas o instrumentos de la evaluación de la CDD son cuestionados por autores como Claro et al. (2024). Estos autores señalan que la diversidad en la forma en que se operacionalizan las CDD resulta en el desarrollo o uso de diferentes instrumentos que evalúan constructos distintos, lo que impide una comparación consistente de los resultados.

Una de las dificultades más frecuentes en la evaluación de competencias y habilidades complejas como las CDD es la falta de estandarización en los instrumentos utilizados y esto no solo afecta la validez y fiabilidad de los resultados, sino que también complica la creación de un marco común que permita evaluar de manera efectiva y comparativa el nivel de competencia en distintos contextos educativos de Colombia, por lo que este estudio se presenta como una valiosa referencia para los profesionales educativos y los diseñadores de políticas públicas en Colombia.

Sin embargo, Lázaro-Cantabrana et al. (2018) aluden a que los docentes deben tener actitud proactiva en relación con su práctica educativa, donde la actualización docente no debe quedar a expensas de las políticas educativas independientemente del modelo o marco de referencia.

La relación entre CDD e IA son importantes en el fortalecimiento de los Objetivos de Desarrollo Sostenible ODS y de las habilidades del siglo XXI. Simuç et al. (2024) afirman que existen una relación positiva y significativa entre las actitudes de los maestros hacia la IA y el desarrollo de competencias, con el impacto más pronunciado en las competencias de gestión educativa.

Al conocer todos los datos a profundidad de los factores y variables significativas en el desarrollo de CDD, el implementar técnicas inteligentes puede ser un salto hacia una propuesta de universalidad de una herramienta capaz de evaluar la CDD ya que características como la retroalimentación y escalabilidad permiten que se adapte a diferentes contextos y usuarios, dando propuesta de mejora en la evaluación de la CDD.

Rodríguez et al. (2021) afirman que los futuros docentes en formación no disponen de herramientas que les ayuden a autoevaluar su propia competencia y obtener feedback instantáneo sobre cómo evoluciona su CDD, por ello, este modelo al ser retroalimentable a nivel de datos tal como afirma Forero-Corba & Negre Bennasar (2024a), puede permitir en futuras investigaciones generar ese feedback de manera instantánea ya que independiente del tamaño de la muestra a estudiar, puede proponer recomendaciones precisas y efectivas.

La confiabilidad del estudio se sustenta en el uso de una rúbrica ya validada (Mantilla Contreras, 2022) específicamente para el contexto docente colombiano. No obstante, la validez del modelo se fortalece mediante el cálculo del AUC, obteniendo un rendimiento promedio de efectividad del 91,9% entre las nueve técnicas de ML aplicadas. Este enfoque técnico responde a las críticas sobre la falta de estandarización en la evaluación de la CDD (Claro et al., 2024), proporcionando un mecanismo de comparación consistente que reduce la subjetividad inherente a los instrumentos de autopercepción. La triangulación con un análisis cualitativo mediante codificación jerárquica en *NVIVO* refuerza la solidez de los hallazgos obtenidos en la fase cuantitativa.

Limitaciones y futuras investigaciones

Aunque el análisis de grandes datos permite predicciones precisas, la evaluación de la CDD se ve limitada por sesgos en las variables disponibles. Datos como salario, edad o carga laboral, cruciales para un análisis efectivo, chocan con estándares éticos, especialmente al usar IA, frenando una evaluación profunda y real.

Las variables usadas estuvieron basadas en la rúbrica de 25 preguntas, no obstante, para un análisis real del valor de predicción de la CDD, es crucial implementar variables adicionales, como sugiere Cattaneo et al. (2022), quienes han identificado variables importantes y poco consideradas en rúbricas que evalúan el desarrollo de la CDD como las demográficas, la carga laboral, factores personales, la actitud hacia la tecnología y la frecuencia de uso de las herramientas digitales, promoviendo una evaluación real de la CDD.

Se podrían explorar estudios longitudinales sobre el desarrollo de estas competencias a lo largo de la carrera docente y en diversos entornos, incluidos los rurales y urbanos. Otra posible línea de investigación sería el uso de tecnologías emergentes, como la IA, para mejorar la personalización y la eficiencia en la evaluación de las CDD.

Para futuros estudios de investigadores sin experiencia en programación pueden usar Orange Data Mining para analizar grandes conjuntos de datos y obtener resultados predictivos valiosos. Su interfaz visual facilita la creación de modelos complejos sin necesidad de escribir código.

Referencias Bibliográficas

- Ahmed, S. K. (2024). How to choose a sampling technique and determine sample size for research: A simplified guide for researchers. In *Oral Oncology Reports* (Vol. 12). Elsevier Ltd. <https://doi.org/10.1016/j.oor.2024.100662>
- Antonietti, C., Cattaneo, A., & Amenduni, F. (2022). Can teachers' digital competence influence technology acceptance in vocational education? *Computers in Human Behavior*, 132. <https://doi.org/10.1016/j.chb.2022.107266>
- Baashar, Y., Hamed, Y., Alkaws, G., Fernando Capretz, L., Alhussian, H., Alwadain, A., & Al-amri, R. (2022). Evaluation of postgraduate academic performance using artificial intelligence models. *Alexandria Engineering Journal*, 61(12), 9867–9878. <https://doi.org/10.1016/j.aej.2022.03.021>
- Bacos, C. A. (2020). Machine Learning and Education in the Human Age: A Review of Emerging Technologies. *Advances in Intelligent Systems and Computing*, 944, 536–543. https://doi.org/10.1007/978-3-030-17798-0_43
- Bellas, F., Guerreiro-Santalla, S., Naya, M., & Duro, R. J. (2022). AI Curriculum for European High Schools: An Embedded Intelligence Approach. *International Journal of Artificial Intelligence in Education*, 33(2), 399–426. <https://doi.org/10.1007/s40593-022-00315-0>
- Cabero-Almenara, J., & Palacios-Rodríguez, A. (2020). Marco Europeo de Competencia Digital Docente «DigCompEdu». Traducción y adaptación del cuestionario «DigCompEdu Check-In». *Edmetic*, 9(1), 213–234. <https://doi.org/10.21071/edmetic.v9i1.12462>
- Cabero-Almenara, J., Barroso-Osuna, J., Llorente-Cejudo, C., & Palacios-Rodríguez, A. (2022). Validación Del Marco Europeo De Competencia Digital Docente Mediante Ecuaciones Estructurales. *Revista Mexicana de Investigación Educativa*, 27(92), 185–208. <https://ojs.rmie.mx/index.php/rmie/article/view/140>
- Caglayan, C. (2019). Comparison of the Code-based or Tool-based Teaching of the Machine Learning Algorithm for the First-Time Learners. *1st International Informatics and Software Engineering Conference: Innovative Technologies for Digital Transformation, IISEC 2019 - Proceedings, November 2019*. <https://doi.org/10.1109/UBMYK48245.2019.8965519>
- Cattaneo, A. A. P., Antonietti, C., & Rauseo, M. (2022). How digitalised are vocational teachers? Assessing digital competence in vocational education and looking at its underlying factors. *Computers and Education*, 176, 104358. <https://doi.org/10.1016/j.compedu.2021.104358>
- Ceha, J., Law, E., Kulić, D., Oudeyer, P. Y., & Roy, D. (2022). Identifying Functions and Behaviours of Social Robots for In-Class Learning Activities: Teachers' Perspective. *International Journal of Social Robotics*, 14(3), 747–761. <https://doi.org/10.1007/s12369-021-00820-7>
- Cheng, J., Chae, M. H. C., & Feng, R. (2021). Stem education-career pathway for emerging forensic analytics: Innovative professional development in multimodal environments. *Journal of Higher Education Theory and Practice*, 21(8), 115–130. <https://doi.org/10.33423/JHETP.V21I8.4509>
- Claro, M., Castro-Grau, C., Ochoa, J. M., Hinostroza, J. E., & Cabello, P. (2024). Systematic review of quantitative research on digital competences of in-service school teachers. *Computers and Education*, 215. <https://doi.org/10.1016/j.compedu.2024.105030>
- De Benito, B., & Salinas, J. M. (2016). La Investigación Basada en Diseño en Tecnología Educativa Design-Based Research in Educational Technology. *Revista Interuniversitaria de Investigación En Tecnología Educativa*, 44–59. <https://doi.org/10.6018/riite2016/260631>
- Departamento Administrativo de la Función Pública. (2012). *Ley 1581 de 2012. In Ley de protección de datos personales*. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=49981>
- Durán, M. C., Prendes, M. P. E., & Gutiérrez, I. P. (2019). Teaching Digital Competence Certification: a proposal for university teachers. *RIED-Revista Iberoamericana de Educacion a Distancia*, 22(1), 187–205. <https://doi.org/10.5944/ried.22.1.22069>

- Esquivel Gámez, I. (2014). *Los Modelos Tecno-Educativos, revolucionando el aprendizaje del siglo XXI*. Editorial Lulu Digital.
- Esteve, F., Castañeda, L., Adell, J., & Baynat, S. (2018). Un modelo holístico de competencia docente para el mundo digital. *Revista Interuniversitaria de Formación del Profesorado*, 97(32.1), 105–116. <https://recyt.fecyt.es/index.php/RIFOP/issue/view/3377>
- Forero-Corba, W., & Negre Bennasar, F. (2024a). Diseño y simulación de un modelo de predicción para la evaluación de la competencia digital docente usando técnicas de Machine Learning. *EduTec, Revista Electrónica de Tecnología Educativa*, 89, 18–43. <https://doi.org/10.21556/edutec.2024.89.3201>
- Forero-Corba, W., & Negre Bennasar, F. (2024b). Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: una revisión sistemática. *RIED-Revista Iberoamericana de Educación a Distancia*, 27(1), 209–253. <https://doi.org/10.5944/ried.27.1.37491>
- Galindo-Domínguez, H., Delgado, N., Campo, L., & Losada, D. (2024). Relationship between teachers' digital competence and attitudes towards artificial intelligence in education. *International Journal of Educational Research*, 126. <https://doi.org/10.1016/j.ijer.2024.102381>
- García-Ruiz, R., Buenestado-Fernández, M., & Ramírez-Montoya, M. S. (2023). Assessment of Digital Teaching Competence: Instruments, results and proposals. Systematic literature review. *Educacion XX1*, 26(1), 273–301. <https://doi.org/10.5944/educxx1.33520>
- Gómez, R., Palacios, A., Moreno-Mediavilla, D., & Barreras, Á. (2022). Teacher competences in the use of STEM virtual simulations: design and validation of a measurement instrument (CDUSV). *Bordon. Revista de Pedagogía*, 74(4), 85–102. <https://doi.org/10.13042/Bordon.2022.94154>
- González Fernández, M. O. (2021). Digital skills of the high school teacher in the face of emergency remote teaching. *Apertura*, 13(1), 6–19. <https://doi.org/10.32870/Ap.v13n1.1991>
- Haleem, A., Javaid, M., Qadri, M. A., & Suman, R. (2022). Understanding the role of digital technologies in education: A review. *Sustainable Operations and Computers*, 3, 275–285. <https://doi.org/10.1016/j.susoc.2022.05.004>
- Houngue, P., Hountondji, M., & Dagba, T. (2022). An Effective Decision-Making Support for Student Academic Path Selection using Machine Learning. *International Journal of Advanced Computer Science and Applications*, 73(11), 727–734. <https://doi.org/10.14569/IJACSA.2022.0131184>
- Instefjord, E. J., & Munthe, E. (2017). Educating digitally competent teachers: A study of integration of professional digital competence in teacher education. *Teaching and Teacher Education*, 67, 37–45. <https://doi.org/10.1016/j.tate.2017.05.016>
- Lázaro-Cantabrana, J. L., Gisbert-Cervera, M., & Silva-Quiroz, J. E. (2018). Una Rubrica Para Evaluar La Competencia Digital Del Profesor Universitario En El Contexto Latinoamericano a Rubric To Evaluate the Digital Competence of the University. *EDUTECH Revista Electrónica de Tecnología Educativa*, (63), 1–14. <https://doi.org/10.21556/edutec.2018.63.1091>
- Mantilla Contreras, M. A. (2022). *Modelo de formación para el desarrollo de competencias digitales en docentes de una universidad del nororiente colombiano* (Tesis doctoral) Universitat de les Illes Balears. <http://hdl.handle.net/10803/688326>
- Martín-Párraga, L., Llorente-Cejudo, C., & Cabero-Almenara, J. (2022). Analysis of teachers' digital competencies from assessment frameworks and instruments. *International Journal of Educational Research and Innovation*, 2022(18), 62–79. <https://doi.org/10.46661/ijeri.7444>
- Ministerio de Educación. (2011). *Competencias y Estándares TIC para la Profesión Docente*. 1–98. <https://bibliotecadigital.mineduc.cl/bitstream/handle/20.500.12365/2151/mono-964.pdf?sequence=1&isAllowed=y>
- Ministerio de Educación Nacional. (2013). *Competencias TIC para el desarrollo profesional docente*. Imprenta Nacional de Colombia. https://www.mineducacion.gov.co/1621/articles-339097_archivo_pdf_competencias_tic.pdf
- Misol Gerlache, H. A., Moreno Ger, P., & de la Fuente Valentín, L. (2022). Towards the Grade's Prediction. A Study of Different Machine Learning Approaches to Predict Grades from Student Interaction Data. *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(4), 196–204. <https://doi.org/10.9781/ijimai.2021.11.007>
- Moreno Padilla, R. D. (2019). La llegada de la inteligencia artificial a la educación. *Revista de Investigación En Tecnologías de La Información*, 7(14), 260–270. <https://doi.org/10.36825/riti.07.14.022>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura. (2019). *Marco de competencias docentes en materia de TIC*. UNESCO Publishing. <https://unesdoc.unesco.org/ark:/48223/pf0000371024>

- Rahman Alzoubaidi, A., Alzoubaidi, M., Abu Mahfouz, I., Alkhamis, T., Fuad Salim AL-Asali, F., & Alzoubaidi, M. (2021). Virtual desktop infrastructure in higher education institution: an application of home and mobile computing environment. *Azerbaijan Journal of High Performance Computing*, 4(1), 29–38. <https://doi.org/10.32010/26166127.2021.4.1.29.38>
- Redecker, C. (2020). *Marco europeo para la competencia digital de los educadores: DigCompEdu*. Secretaría General Técnica del Ministerio de Educación y Formación Profesional. <https://sede.educacion.gob.es/publiventa/d/24685/19/0>
- Rodríguez, M. U., Cantabrana, J. L. L., & Cervera, M. G. (2021). Validation of a tool for self-evaluating teacher digital competence. *Educacion XX1*, 24(1), 353–373. <https://doi.org/10.5944/educXX1.27080>
- Secretaría de Educación Pública. (2020). *Agenda digital educativa*. https://siteal.iiep.unesco.org/sites/default/files/sit_accion_files/10313.pdf
- Segbenya, M., Bervell, B., Frimpong-Manso, E., Otoo, I. C., Andzie, T. A., & Achina, S. (2023). Artificial intelligence in higher education: Modelling the antecedents of artificial intelligence usage and effects on 21st century employability skills among postgraduate students in Ghana. *Computers and Education: Artificial Intelligence*, 5. <https://doi.org/10.1016/j.caeai.2023.100188>
- Segura, M., Mello, J., & Herná, A. (2022). *Machine Learning Prediction of University Student Dropout: Does Preference Play a Key Role? Mathematics*, 10(18), 3359. <https://doi.org/https://doi.org/10.3390/math10183359>
- Simuț, R., Simuț, C., Bădulescu, D., & Bădulescu, și A. (2024). Artificial Intelligence and the Modelling of Teachers' Competencies. *Amfiteatru Economic*, 26(65), 187–206. <https://doi.org/10.24818/EA/2024/65/181>
- Tarik, A., Aissa, H., & Yousef, F. (2021). Artificial intelligence and machine learning to predict student performance during the COVID-19. *Procedia Computer Science*, 184, 835–840. <https://doi.org/10.1016/j.procs.2021.03.104>
- Yamamoto, S. H., & Alverson, C. Y. (2022). From high school to postsecondary education, training, and employment: Predicting outcomes for young adults with autism spectrum disorder. *Autism and Developmental Language Impairments*, 7. <https://doi.org/10.1177/23969415221095019>
- Zhao, W. (2024). A study of the impact of the new digital divide on the ICT competences of rural and urban secondary school teachers in China. *Heliyon*, 10(7). <https://doi.org/10.1016/j.heliyon.2024.e29186>