



Diseño y simulación de un modelo de predicción para la evaluación de la competencia digital docente usando técnicas de Machine Learning

Design and simulation of a predictive model for the evaluation of teachers' digital competence using Machine Learning techniques

 Wiston Forero-Corba; wiston.forero@uib.es

 Francisca Negre Bennasar; xisca.negre@uib.es

Universitat de les Illes Balears (España)

Resumen

Machine Learning (ML) es un campo de la inteligencia artificial que, a través de técnicas, elabora predicciones de datos masivos. La competencia digital docente (CDD) refiere comúnmente a las habilidades y destrezas de los docentes en sistemas digitales y su aplicación en los procesos de enseñanza-aprendizaje. La investigación sobre CDD es importante para las instituciones, ya que de su evaluación dependen el aprendizaje, trayectoria, dirección y comportamiento de los alumnos. La CDD en Colombia se basa en 5 elementos: Comunicativa, de gestión, investigativa, pedagógica y tecnológica, y cada uno de ellos se mide en tres niveles: Explorador, integrador e innovador. Las preguntas de investigación fueron: (1) ¿Qué tipo de resultados podemos esperar de la predicción de la CDD con técnicas de ML? (2) ¿Qué técnicas de ML son efectivas para predecir la CDD? (3) ¿Qué ventajas trae predecir la CDD con técnicas de ML? La metodología pretende diseñar un modelo de predicción de la CDD en Colombia aplicando 9 técnicas de ML usando el software *Orange Data Mining*. Los resultados muestran la alta efectividad que tienen las técnicas inteligentes para predecir la CDD. El modelo muestra que es retroalimentable, escalable y permite proponer itinerarios personalizados de aprendizaje.

Palabras clave: competencia digital docente, machine learning, inteligencia artificial, aprendizaje adaptativo, tecnología emergente

Abstract

Machine Learning (ML) is a field of artificial intelligence that uses techniques to make predictions from massive data. Teachers' Digital Competence (TDC) commonly refers to teachers' skills and abilities in digital systems and their application in teaching and learning processes. TDC research is important for institutions, since student learning, trajectory, direction, and behavior depend on its evaluation. TDC in Colombia is based on 5 elements: Communicative, management, investigative, pedagogy and technology, and each of them is measured at three levels: exploratory, integrative, and innovative. The research questions are: (1) What kind of results can we expect from CDD prediction with ML techniques? (2) What ML techniques are effective in predicting TDC? (3) What are the advantages of predicting TDC with ML techniques? The methodology aims to design a prediction model of TDC in Colombia through the application of 9 ML techniques using *Orange Data Mining* software. The results show the high effectiveness of intelligent techniques to predict TDC. The model demonstrates that it is feedbackable, scalable and allows proposing personalized learning itineraries.

Keywords: teachers' digital competence, machine learning, artificial intelligence, adaptive learning, emerging technology

1. INTRODUCCIÓN

Machine Learning (ML) es un campo de la inteligencia artificial (IA) que elabora predicciones de grandes datos a partir de diferentes técnicas o algoritmos (Tarik et al., 2021) que ayudan en la toma de decisiones. El sector educativo se ve cada vez más influenciado por software con IA que potencia la productividad, la escritura, la gramática, la creación de vídeos, diseños y marketing. Herramientas como *ChatGPT 4.0*, *DALL-E*, *Midjourney*, *Instanttext*, *Bing*, *Adobe Enhance*, *Capcut*, *iContact*, *Robin* y muchas otras están revolucionando las prácticas computacionales. Incluso *Canva*, el editor online, incorpora herramientas de IA para crear diseños automáticamente.

La IA y el ML presentan un gran potencial para transformar la educación, impulsando metodologías activas e innovadoras como los proyectos STEAM en todos los niveles educativos. Estos proyectos fomentan el pensamiento crítico y la conciencia ciudadana. El ML, uno de los campos más exitosos de la IA, optimiza la productividad al automatizar tareas repetitivas, permitiendo a los docentes enfocarse en tareas más creativas y de mayor impacto (Dúo Terrón et al., 2023).

El ML y el Big Data se posicionan como pilares fundamentales en la evolución ascendente de la producción científica. Los altos indicadores bibliométricos, convierte estas áreas en focos de atención para organizaciones y países que buscan impulsar el conocimiento y la productividad (Belmonte et al., 2020).

La competencia digital docente (CDD) es fundamental para el aprendizaje de los alumnos. Esta competencia se refiere a las habilidades, estrategias y conocimientos propios de los docentes en sistemas digitales y su aplicación en los procesos de enseñanza-aprendizaje (Prendes Espinosa et al., 2018). Permite a los docentes solucionar los problemas y retos educativos que plantea la sociedad del conocimiento (Cabero-Almenara et al., 2020).


Para garantizar la eficacia de la formación, identificar los factores que la mejoran y reducir los factores que la perjudican (García-Ruiz et al., 2023) es necesario investigar mecanismos que ayuden a predecir y evaluar la CDD.

La evaluación del profesorado tiene como propósito valorar el desempeño de los docentes en las distintas facetas de su labor pedagógica (Flores et al., 2021). La CDD se adapta a cada contexto geográfico y responde a las necesidades educativas específicas de cada región. La evaluación del profesorado, estrechamente ligada a la CDD, se ha visto enriquecida por la existencia de diversos marcos de referencia de competencias, como por ejemplo el Marco Europeo de Competencia Digital del Profesorado DigCompEdu (Redecker, 2020), Estándares ISTE para Educadores (International Society for Technology in Education, 2019), Marco UNESCO de competencia TIC para Docentes (UNESCO, 2021), Marco Común español de Competencia Digital Docente (INTEF, 2017), Competencias TIC para el desarrollo profesional docente colombiano (Ministerio de Educación Nacional, 2013), Competencias y Estándares TIC para la TIC para la profesión docente en Chile (Elliot, Jaime; Gorichon, Solange; Irigoín, María; Maurizi, 2011), entre otros.

La pandemia evidenció la falta de preparación de los docentes colombianos para la transición a la virtualidad. Por ello en Colombia, fue necesario fortalecer la CDD a través de la formación docente. La CDD comprende 5 dimensiones comunicativa, de gestión, investigativa, pedagógica y tecnológica (Figura 1): Estos elementos se miden en tres niveles: explorador, integrador e innovador (Ministerio de Educación Nacional, 2013).

Figura 1

Pentágono de competencias TIC



Nota. Tomado de Ministerio de Educación Nacional (2013)

La formación y capacitación previa al empleo en CDD ayuda a los futuros docentes a desarrollar las habilidades y conocimientos necesarios para utilizar las tecnologías digitales (TD) en el aula. Esto les permite reflexionar de forma crítica sobre el valor añadido de las TD en la enseñanza (Lucas et al., 2021). Es así, que la relación de los futuros profesionales de la educación en su día a día con dispositivos electrónicos facilita la practica educativa, brindándoles confianza para optar positivamente con su continua formación digital docente (Salmerón Majadas, 2018).

La mejora de las CDD ayuda a los estudiantes a desarrollar las habilidades y conocimientos necesarios para utilizar estas tecnologías de manera efectiva facilitando la creación de ambientes de aprendizaje innovadores y atractivos. Esto les permite participar plenamente en la sociedad actual, cada vez más digital (Silva et al., 2019). Por tanto, la CDD puede ayudar al docente en la mejora de su práctica educativa y al aprendizaje por parte de los estudiantes aumentando la motivación y compromiso con su proceso académico (Forero-Corba & Negre-Bennasar, 2024).

Investigaciones previas han identificado variables predictoras de los niveles de la CDD. Cabero-Almenara et al. (2022) midieron, evaluaron y analizaron las competencias digitales de los docentes universitarios centrados en el modelo *DigCompEdu*. En este estudio, utilizaron el modelo de ecuaciones estructurales para predecir los niveles de la CDD. Gómez et al. (2022) propusieron la medición de la CDD centrada en simulaciones virtuales.

Moreno-Padilla (2019) sostiene que la implementación de la IA en la educación puede ser lenta debido a las políticas y procesos administrativos de cada país. Salas-Pilco et al. (2022) afirman que la tasa de adopción de la IA y el análisis de aprendizaje en la educación es lenta, en comparación con otros campos como la medicina, la industria y las finanzas. Sin embargo, en 2023, ya es una realidad en varios países, lo que su progreso y aceleración exponencial plantean importantes desafíos para el sector educativo (Dai et al., 2022).

La enseñanza de la IA en las escuelas primarias, junto con métodos multidisciplinares innovadores para desarrollar habilidades y competencias, ayuda a mejorar los sistemas educativos de forma integral (Denys & Klimczuk, 2022). Es por ello, que la alfabetización digital permite comprender más a profundidad sobre la verdadera utilidad y practicidad de la IA (Moreno Padilla, 2019). En este contexto, es necesario incorporar elementos necesarios para fortalecer los marcos de la CDD con técnicas inteligentes. Esto permitirá no solo estar a la vanguardia digital, sino también mejorar aspectos de los entornos educativos, como la formación docente, los procesos de alfabetización digital, la actualización del currículo y la personalización de la enseñanza (Bartolomé et al., 2018).

El objetivo de esta investigación es diseñar un modelo de predicción para evaluar 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 (Figura 1).

Las preguntas de investigación (PI) planteadas son:

- PI1: ¿Qué tipo de resultados podemos esperar de la predicción de la CDD con técnicas de ML?
- PI2: ¿Qué técnicas de ML son efectivas para predecir la CDD?
- PI3: ¿Qué ventajas trae predecir y evaluar la CDD con técnicas de ML?

2. MÉTODO

2.1. Diseño de la investigación


El diseño de la investigación está fundamentado en la Investigación Basada en Diseño (IBD) (De Benito & Salinas, 2016) ya que permite que el diseño y desarrollo del entorno enriquecido con ML pueda implementarse y evaluarse correctamente en futuras investigaciones para explorar procesos educativos innovadores y generar soluciones reales y de gran impacto en la práctica educativa haciendo uso de la IA.

Se implementó el modelo IBD basado en el Modelo ADDIE (Esquivel Gámez, 2014). La IBD se caracteriza por la iteración de sus fases. Esta iteración permitió un proceso continuo de revisión y reformulación del proyecto.

El modelo final para la sección del diseño se presenta en la Figura 2. Las fases de esta investigación se centraron únicamente en el diseño y desarrollo, teniendo en cuenta que las fases previas de análisis y exploración ya se efectuó en una anterior investigación. Sin embargo, el diseño de la herramienta tecnológica en la parte de evaluación se validó para confirmar las estrategias potenciadas por los principios de diseño y mejoras de innovación.

Figura 2

Modelo IBD tipo ADDIE para la investigación



2.2. Diseño Marco Competencia Digital Docente

El marco de la CDD se basa en el marco de Competencias TIC para el desarrollo del docente colombiano. Para ello, se seleccionó una rúbrica de evaluación validada (Mantilla Contreras, 2022) de 25 ítems. La rúbrica se encuentra como anexo en la sección 7.2. Esta rúbrica sirve para medir y evaluar las competencias digitales de docentes universitarios y no universitarios.

2.3. Competencias

Las siguientes definiciones de las competencias fueron tomadas del marco de *Competencias TIC para el Desarrollo Profesional Docente* (Ministerio de Educación Nacional, 2013).

Competencia comunicativa: Capacidad para expresarse, establecer contacto y relacionarse en espacios virtuales y audiovisuales a través de diversos medios y con el manejo de múltiples lenguajes, de manera sincrónica y asincrónica.

Competencia de gestión: Capacidad para utilizar las TIC en la planeación, organización, administración y evaluación de manera efectiva de los procesos educativos; tanto a nivel de prácticas pedagógicas como de desarrollo institucional.

Competencia investigativa: Capacidad de utilizar las TIC para la transformación del saber y la generación de nuevos conocimientos.

Competencia pedagógica: Capacidad de utilizar las TIC para fortalecer los procesos de enseñanza y aprendizaje, reconociendo alcances y limitaciones de la incorporación de estas tecnologías en la formación integral de los estudiantes y en su propio desarrollo profesional.

Competencia tecnológica: Capacidad para seleccionar y utilizar de forma pertinente, responsable y eficiente una variedad de herramientas tecnológicas entendiendo los principios que las rigen, la forma de combinarlas y las licencias que las amparan.

2.4. Niveles

El desarrollo profesional docente en el ámbito de las TIC se evalúa a través de tres niveles progresivos, que permiten identificar el avance y la consolidación de las competencias en cada etapa. Estos niveles son:

- Explorador
- Integrador
- Innovador

La definición particular de cada nivel, en función de la competencia requerida, se especifica en el [anexo 7.1.](#)

2.5. Instrumentos de medida

Se utilizó *Orange Data Mining* 3.35.0 para procesar y analizar la información. Los datos de entrenamiento y prueba se agruparon en una hoja de cálculo .csv. Se seleccionó este software por ser una herramienta gráfica, intuitiva y fácil de usar que implementa técnicas de ML. Esto permite que investigadores con un conocimiento mínimo en ciencia de datos y pensamiento computacional puedan implementarlo sin dificultad (Caglayan, 2019).

2.6. Datos

El marco de CDD define los datos utilizados en este estudio. La rúbrica (ver Anexo) sirve para medir y evaluar la CDD. Las variables entrenadas o variables predictoras, que en este caso son las preguntas de la rúbrica, se denominan "*Datos de entrenamiento*". Estos datos permiten enseñar a la máquina a clasificar correctamente los datos de entrada. Al enfocarse en el diseño del modelo, este estudio utiliza como datos de entrada información simulada que refleja las respuestas de los docentes a la rúbrica validada, denominándola "*Datos de prueba*".

2.6.1. Datos de Entrenamiento

En la Figura 3 se observa el widget *File Train* donde importamos los datos de entrenamiento, lo cuales nos permiten enseñarle al modelo como clasificar correctamente. Para enseñarle o entrenar nuestro modelo de predicción de las 5 competencias del CDD, en *File Train* hemos incorporado un conjunto de 21.248 variables. Estas variables nos permiten identificar patrones y relaciones clave en los datos. Las variables descriptor 1-7 (rango 1-4) y el promedio (rango 1-4) se usan para entrenar la variable objetivo "nivel de competencia" (explorador, integrador o innovador).

2.6.2. Datos de Prueba

La Figura 3 presenta el widget *File Test*, el cual importa los resultados obtenidos al aplicar la rúbrica a un conjunto de 25 docentes simulados. Estos datos sirven como insumo para nuestro modelo predictivo. En este widget se visualizan las variables utilizadas en el modelo, permitiendo evaluar su desempeño. Los docentes están identificados en una nueva variable llamada ID. Para identificarlos fácilmente etiquetamos a cada docente con las letras del [A, B, C, D, E, F,..., Z]. Para cada variable descriptor, se establecieron respuestas aleatorias. Como

existen 25 docentes, cada uno tiene definido 5 competencias, por tanto, se definen 125 instancias.

2.7. Técnicas de Machine Learning

La Tabla 1 define las nueve técnicas de *ML* utilizadas en el modelo predictivo de la CDD.

Tabla 1

Técnicas de Machine Learning utilizadas en el modelo

N	Abreviatura	Técnica	Definición
1	kNN	<i>k-Nearest Neighbors</i>	<i>kNN</i> busca los <i>k</i> ejemplos de entrenamiento más cercanos en el espacio de características y utiliza su media como predicción.
2	LR	<i>Logistic Regression</i>	<i>Logistic Regression</i> es un modelo estadístico que predice la probabilidad de que ocurra un evento. Se basa en la función logística, que transforma valores continuos en valores probabilísticos.
3	DS	<i>Decision Tree</i>	<i>Tree</i> es un algoritmo que divide los datos en nodos en función de la de clase. Para variables categóricas, utiliza la ganancia de información, y para variables numéricas, utiliza el error cuadrático medio. <i>Tree</i> es precursor de <i>Random Forest</i> . <i>Tree</i> puede manejar conjuntos de datos tanto categóricos como numéricos.
4	RF	<i>Random Forest</i>	<i>Random Forest</i> es un algoritmo que construye un conjunto de árboles de decisión. Cada árbol se desarrolla a partir de una muestra aleatoria de los datos de entrenamiento. Para reducir la varianza, cada árbol se construye utilizando un subconjunto aleatorio de atributos. El modelo final se basa en el voto mayoritario.
5	NB	<i>Naive Bayes</i>	El algoritmo <i>Naive Bayes</i> se utiliza para clasificar datos y se basa en el teorema de Bayes. Calcula la probabilidad de cada clase, dado el conjunto de características. La clase con la probabilidad más alta es la clase predicha. Es un algoritmo simple y eficiente para conjunto de datos con gran número de características.
6	GB	<i>Gradient Boosting</i>	<i>Gradient Boosting</i> es un algoritmo para problemas de regresión y clasificación, que produce un modelo de predicción fuerte a partir de conjunto de modelos de predicción débiles. El nuevo modelo se entrena para reducir el error del modelo anterior, y luego se agrega al modelo final.
7	SVM	<i>Support Vector Machine</i>	<i>SVM</i> separa datos de dos clases con un hiperplano, maximizando el margen entre clases. Es eficaz en problemas de clasificación lineal donde los datos se pueden separar con un hiperplano lineal.
8	SGD	<i>Stochastic Gradient Descent</i>	<i>SGD</i> usa la función del gradiente descendente estocástico para minimizar una función de pérdida con una función lineal. Se aproxima al gradiente real con una muestra cada vez y actualiza el modelo simultáneamente. Es útil para conjuntos de datos a gran escala y dispersos.
9	NN	<i>Neural Network</i>	<i>NN</i> es un algoritmo inspirado en el cerebro humano. Se compone de neuronas artificiales interconectadas, similar a las neuronas biológicas. Su objetivo es aprender a realizar una tarea a partir de datos de entrenamiento. La red aprende a identificar patrones y usarlos para realizar la tarea.

2.8. Validación del modelo

La validación del diseño del prototipo está basada por el método *validez del criterio predictivo* (Ramírez Martínez, 2019), donde refiere la capacidad de un instrumento de medición para predecir un futuro resultado en base a la probabilidad de éxito en un programa de entrenamiento. La validez de criterio asocia el rendimiento del instrumento y la toma de decisiones, utilizando como medida de validación el área bajo la curva AUC (*Area Under the ROC Curve*) y la precisión (López et al., 2019).

En la Tabla 2 se evidencia los 4 *widgets* usados en *Orange Data Mining* para validar el modelo y ver resultados.

Tabla 2

Widgets usados en Orange Data Mining para validar el modelo

Widgets	Icono	Definición
<i>Test and Score</i>	 Test and Score	Prueba algoritmos de aprendizaje. Muestra una tabla con diferentes medidas de rendimiento del clasificador, como la precisión de la clasificación y el AUC.
<i>Confusion Matrix</i>	 Confusion Matrix	Tabla que muestra el número o proporción de instancias correcta y erróneamente clasificadas por un modelo.
<i>Feature Statistics</i>	 Feature Statistics	Tabla que muestra el número o proporción de instancias correcta y erróneamente clasificadas por un modelo.
<i>Scatter Plot</i>	 Scatter Plot	Muestra la visualización de gráficos de dispersión con análisis exploratorio y mejoras inteligentes de visualización de datos.

3. RESULTADOS


La Figura 3 muestra el diseño del modelo de predicción. Se incorporan 9 técnicas de ML. El widget *Predictions* permite clasificar por técnica. Los widgets *Data Table Train* y *Scatter Plot Train* visualizan los datos de entrenamiento. Los widgets *Data Table Test* y *Scatter Plot Test* visualizan los datos de prueba. La predicción de datos de prueba se visualiza combinando *File Test* y *Predictions*. *Data Table Test* está conectado con *File Test*, por lo que se puede combinar con *Predictions* para visualizar las predicciones.

Además, se introducen los widgets *Test and Score*, *Confusion Matrix* y *Feature statistics* para la validación del modelo.

Por último, se agregan tres widgets *Select Columns*, *Data Table Output* y *Save Data*, con el fin de seleccionar y exportar los resultados que necesitemos para la toma de decisiones.

Figura 3

Diseño del modelo




Para responder a la primera pregunta de investigación, se analizaron las Figuras 9, 10, 11 y 12, así como las Tablas 3 y 4.

PI1: ¿Qué tipo de resultados podemos esperar de la predicción de la CDD con técnicas de ML?

La Figura 4 muestra la agrupación de los 21.248 datos entrenados para la predicción de los datos de prueba frente a las variables de Competencia vs Nivel de competencia.

Figura 4


Agrupación datos de entrenamiento



La Figura 5 muestra la agrupación de las técnicas de ML para la predicción de la CDD. Cada punto representa la competencia docente en el nivel correspondiente. El contorno muestra la CDD de los 25 docentes simulados. Los datos aleatorios ubican la CDD docente en gran porcentaje en los niveles explorador e integrador para las 9 técnicas.

Figura 5

Visualización de la predicción de las CDD con las 9 técnicas de ML



La Tabla 3 muestra los resultados estadísticos centrados en los descriptores de la rúbrica. Las variables estadísticas medidas fueron media, mediana, dispersión, valor mínimo y valor máximo.

Tabla 3

Resultados estadísticos de los descriptores

Descriptores	Media	Mediana	Dispersión	Mínimo	Máximo
Descriptor 1	2.22	2	0.51	1	4
Descriptor 2	2.13	2	0.47	1	4
Descriptor 3	2.06	2	0.52	1	4
Descriptor 4	2.05	2	0.49	1	4
Descriptor 5	2.26	2	0.42	1	4
Descriptor 6	2.34	2	0.44	1	4
Descriptor 7	2.40	2	0.44	1	4

La Tabla 3 muestra el rendimiento que cada una de las técnicas usadas para la predicción de la CDD.

PI2: ¿Qué técnicas de ML son efectivas para predecir la CDD?

Para responder la segunda pregunta de investigación, se analizó la Tabla 4.

La Tabla 4 muestra que el AUC y Precisión para las técnicas *Logistic Regression*, *Decision Tree*, *Random Forest*, *Gradient Boosting* y *Neural Network* son del 100%, con ello, podemos afirmar que el entrenamiento de los 21.248 datos fue bastante efectivo para que nuestro modelo predijera la CDD y que estas técnicas son las más efectivas para poder predecir las Competencias TIC del docente colombiano.

Tabla 4

Rendimiento de las técnicas de ML mediante AUC y Precisión

Técnica	AUC	Precisión
<i>k-Nearest Neighbors</i>	0.941	0.850
<i>Logistic Regression</i>	1.000	1.000
<i>Decision Tree</i>	1.000	1.000
<i>Random Forest</i>	1.000	1.000
<i>Naive Bayes</i>	0.978	0.920
<i>Gradient Boosting</i>	1.000	1.000
<i>Support Vector Machine</i>	0.998	0.988
<i>Stochastic Gradient Descent</i>	0.902	0.952
<i>Neural Network</i>	1.000	1.000

Nota. Elaboración propia

La Figura 6 muestra la matriz de confusión únicamente para las técnicas *kNN*, *NB*, *SVM* y *SGD*, debido a que según la Tabla 4, fueron técnicas donde no llegaron al 100%, clasificando incorrectamente los datos de prueba.

Figura 6

Matriz de confusión para las técnicas kNN, NB, SVM y SGD

Predicted <i>kNN</i>					Predicted <i>Naive Bayes</i>				
	1_Explorador	2_Integrador	3_Innovador	Σ		1_Explorador	2_Integrador	3_Innovador	Σ
1_Explorador	1371	618	0	1989	1_Explorador	1550	439	0	1989
2_Integrador	538	14507	668	15713	2_Integrador	0	13879	1834	15713
3_Innovador	0	1289	2257	3546	3_Innovador	0	0	3546	3546
Σ	1909	16414	2925	21248	Σ	1550	14318	5380	21248

Predicted <i>SVM</i>					Predicted <i>SGD</i>				
	1_Explorador	2_Integrador	3_Innovador	Σ		1_Explorador	2_Integrador	3_Innovador	Σ
1_Explorador	1975	14	0	1989	1_Explorador	1143	846	0	1989
2_Integrador	13	15602	98	15713	2_Integrador	0	15698	15	15713
3_Innovador	0	133	3413	3546	3_Innovador	0	217	3329	3546
Σ	1988	15749	3511	21248	Σ	1143	16761	3344	21248

La Figura 7 muestra una matriz de comparación de las 9 técnicas de ML entre sí. En ella, podemos ver qué técnica es más efectiva contra otra técnica.

Figura 7

Matriz de comparación entre técnicas de ML

	Gradient Boosting	kNN	Logistic Regressi...	Naive Bayes	Neural Network	Random Forest	SGD	SVM	Tree
Gradient Boosting		1.000	0.500	0.999	0.500	0.500	1.000	0.955	0.500
kNN	0.000		0.000	0.000	0.000	0.000	0.989	0.000	0.000
Logistic Regression	0.500	1.000		0.999	0.500	0.500	1.000	0.955	0.500
Naive Bayes	0.001	1.000	0.001		0.001	0.001	0.999	0.001	0.001
Neural Network	0.500	1.000	0.500	0.999		0.500	1.000	0.955	0.500
Random Forest	0.500	1.000	0.500	0.999	0.500		1.000	0.955	0.500
SGD	0.000	0.011	0.000	0.001	0.000	0.000		0.000	0.000
SVM	0.045	1.000	0.045	0.999	0.045	0.045	1.000		0.045
Tree	0.500	1.000	0.500	0.999	0.500	0.500	1.000	0.955	

PI3: ¿Qué ventajas trae predecir y evaluar la CDD con técnicas de ML?

A continuación, se denotan las ventajas que puede tener el predecir la CDD con técnicas de ML.

Retroalimentación: El análisis de grandes cantidades de datos permite que las técnicas de ML se alimenten de información de forma constante para predecir de forma correcta las competencias digitales de cada docente. Esta información puede ayudar a los directivos docentes a tomar decisiones sobre cómo enfocar la alfabetización digital o el desarrollo profesional de los docentes en la institución. El modelo diseñado permite categorizar a los docentes y agregar nuevas muestras (docentes) para compararlos con muestras antiguas (docentes ya incluidos en el modelo). Con estas predicciones, se pueden tomar decisiones correctas para el crecimiento y la actualización profesional del nuevo docente en la institución.

Escalabilidad: Las técnicas de ML puede favorecer a la aplicación de modelos de predicción de la CDD en diferentes contextos. El diseño del modelo desarrollado permite adaptarse fácilmente a instrumentos o marcos de competencia digital de otros países, únicamente se debe ajustar las variables tanto de entrenamiento como de prueba, de acuerdo con la parametrización de variables que conlleve el marco.

Habilidades del siglo XXI: El uso de técnicas inteligentes en la predicción de la CDD permite desarrollar las habilidades que los docentes necesitan actualmente para desempeñarse de manera eficaz en el aula, especialmente en contextos educativos dinámicos.

Desarrollo sostenible: El uso de técnicas de ML para la predicción de la CDD permite ir a la vanguardia del desarrollo tecnológico y mejorar el cuarto objetivo de desarrollo sostenible, que se centra en la educación inclusiva, equitativa y de calidad para generar oportunidades de aprendizaje (Organización de la Naciones Unidas, 2018).

4. DISCUSIÓN Y CONCLUSIONES

El modelo diseñado y desarrollado en la investigación ayuda a predecir y evaluar la CDD usando técnicas de ML. Este diseño es escalable y adaptable a instrumentos o marcos de competencia digital de otros países. Esto se logra ajustando las variables de entrenamiento y prueba a la parametrización del marco en cuestión. Además, el modelo permite la retroalimentación a nivel de datos, ya que puede almacenar grandes cantidades de muestras. Con estas muestras, se puede predecir correctamente la competencia digital de un docente o grupo de docentes de una institución educativa.

Instituciones educativas están generando iniciativas para orientar y mejorar el desarrollo de la CDD de acuerdo con las estandarizaciones del marco, incluyendo parámetros de mejora con respecto a otros marcos de competencia de nivel internacional (Silva et al., 2019). Diseñar y desarrollar un modelo de predicción con técnicas de ML motiva a las instituciones a implementar modelos para evaluar la CDD, especialmente con herramientas enriquecidas con IA. El uso de herramientas enriquecidas con IA puede ayudar a las instituciones a mejorar la eficiencia y precisión de la evaluación de la CDD.

En el ámbito de la IA, nos encontramos con sistemas o procesos cuyo funcionamiento interno permanece oculto o inaccesible para el usuario, lo que se conoce como *black box* (Bearman & Ajjawi, 2023). A pesar de que estos sistemas inteligentes pueden generar resultados precisos, la falta de comprensión sobre el proceso que los lleva a esas conclusiones plantea interrogantes en torno a una visión política y ética (Suárez-Guerrero et al., 2020). Por ello, se debe tener en cuenta consideraciones éticas clave como la transparencia, sesgo algorítmico, privacidad y seguridad en los datos e.t.c, para garantizar que sistemas inteligentes se utilicen de manera responsable en beneficio de la sociedad (UNESCO, 2019).

La importancia de establecer niveles de desarrollo de la CDD mediante un instrumento o rúbrica permite evaluar las habilidades docentes frente a herramientas tecnológicas que son clave para autorregular los actuales procesos de enseñanza-aprendizaje (Gisbert & Lázaro, 2018). Por ello, la rúbrica ya evaluada por Mantilla Contreras (2022), es efectiva para la investigación porque mide las competencias digitales de los docentes colombianos, sean o no universitarios. La rúbrica establece las 5 competencias en los 3 niveles que son variables estandarizadas por el Ministerio de Educación Nacional.

Los datos para el análisis de la CDD se obtuvieron a partir de los descriptores establecidos en la rúbrica. La rúbrica de evaluación propuesta puede utilizarse en procesos de evaluación, ya sea de forma autoevaluativa o externa. El diseño del modelo, a partir de los resultados predictivos de los niveles de competencias, puede orientar la toma de decisiones de los docentes (en la modalidad de autoevaluación) o de las instituciones educativas y organizaciones del sector educativo (en modalidad de evaluación externa) frente a las necesidades formativas.

Investigaciones de la evaluación de la competencia digital implementan variables predictoras sociodemográficas para la predicción de la CDD como por ejemplo *edad, genero, experiencia docente, experiencia TIC*, entre otras (Cabero-Almenara et al., 2022). El implementar variables sociodemográficas junto con las variables de la rúbrica o instrumentos de evaluación mejoraría

la predicción de la CDD. Además, puede ser efectiva al momento de aplicar nuevas muestras para el proceso de retroalimentación, autoaprendizaje y escalabilidad del modelo.

La validación del modelo estuvo dada por la validez del criterio predictivo, donde el resultado predicho de las técnicas de ML se centra en la probabilidad de éxito de los datos de entrenamiento frente a los de prueba, comparando así resultados. López et al. (2019) afirma que si el área bajo la curva AUC es mayor de 0.9, el instrumento aplicado en el modelo es excelente, por lo tanto, el diseño del modelo predictivo se ajusta a los elementos de evaluación de la CDD dado que todas las predicciones de las técnicas de ML estuvieron por encima del 0.9 como se especifica en la Tabla 4.

Estudios basados en la aplicación de herramientas con técnicas inteligentes han desarrollado modelos con un valor de predicción alrededor del 99%. Un ejemplo de ello es el estudio de Houngue et al. (2022), en el que se estimó el rendimiento académico de estudiantes de una institución educativa a partir de técnicas de aprendizaje automático, obteniendo un 99% de precisión en la predicción.

El software *Orange Data Mining* fue fundamental en el diseño y desarrollo del modelo de predicción de la CDD al ser una herramienta para el análisis y minería de datos. Este software incorpora variadas técnicas de ML, lo que permite mostrar diferentes tipos de resultados, como parámetros estadísticos, matrices de evaluación, visualización predictiva numérica y/o gráfica. Estas características lo convierten en una herramienta muy poderosa para implementar modelos enriquecidos con IA. Además, Caglayan (2019) señala que esta *Orange Data Mining* es muy fácil de implementar al ser de modo gráfico, lo que le da versatilidad en ambientes tanto de desarrollo e investigación.

Las nueve técnicas de ML aplicadas se tomaron del software *Orange Data Mining*, ya que estaban predefinidas. Estas técnicas son bien conocidas en el campo de las ciencias de la computación y análisis de datos, donde su implementación en entornos de desarrollo e investigación está en constante crecimiento (Forero-Corba & Bennasar, 2024). Sin embargo, a pesar de las investigaciones sobre la implementación de la IA en educación, Moreno Padilla (2019) expone que aún quedan muchos elementos por trabajar y organizar antes de que sea posible una verdadera implementación de la IA en la educación. En este sentido, implementar técnicas de ML en procesos de alfabetización digital y desarrollo profesional docente podría ser uno de los pasos que se han dado para una implementación efectiva de la IA en el sector educativo.

La Figura 5 presenta 9 gráficos que ilustran el nivel de competencia de cada docente en cada una de las técnicas implementadas en el diseño del modelo. Estos gráficos agrupan los datos por niveles de competencia siguiendo la resolución de la rúbrica definida. Se observa una concentración de predicción de los resultados en los niveles 2 (Integrador) y 1 (Explorador). El modelo predice una cantidad mínima de datos de prueba en el nivel 3 (Innovador). Los resultados sugieren que las directivas docentes deben implementar planes y estrategias de formación y actualización pedagógica y digital para los docentes. Esto permitirá mejorar sus habilidades y aumentar su nivel de competencia, especialmente en el nivel 3 (Innovador).

La predicción y evaluación de la CDD con técnicas inteligentes permite cerrar la brecha digital mediante la mejora de los procesos de enseñanza-aprendizaje, la actualización del currículo, el

aumento del rendimiento académico y la disminución de la deserción escolar. Pérez-Escoda et al. (2021) señalan que las principales competencias digitales que debe tener todo docente para disminuir la brecha digital son: Conocimiento de las herramientas digitales, autopercepción de las propias competencias digitales, dominio de las competencias digitales para el desempeño profesional, grado de competencia digital de los alumnos e inclusión curricular de las competencias digitales.

5. LIMITACIONES Y FUTURAS INVESTIGACIONES

El modelo se entrena y prueba con las variables de la rúbrica. No obstante, para aumentar la precisión en la predicción de la CDD, se aconseja incorporar más variables al modelo, como las sociodemográficas (edad, sexo, nivel educativo) y las relacionadas con la trayectoria profesional (experiencia docente, formación en TIC). Estas variables adicionales permitirían obtener una mejor evaluación de las características de los docentes como su familiaridad con las nuevas tecnologías, su capacidad de aprendizaje y su disposición a experimentar con nuevas metodologías.

Para robustecer la evaluación de la CDD, se recomienda la aplicación de otras rúbricas e instrumentos ya validados en futuros estudios. Esto permitirá contrastar los resultados del modelo actual y fortalecer la confiabilidad de las predicciones. Diversos estudios, como los de Gisbert & Lázaro (2018), Gómez et al. (2022), García Tamarit et al. (2021), Cabero-Almenara & Palacios-Rodríguez (2020) y Touron et al. (2018), proponen rúbricas e instrumentos validados que pueden ser utilizados para este fin. La escalabilidad del modelo actual facilita la incorporación de estas herramientas adicionales, lo que permitirá obtener una medición y evaluación más completa y precisa de la CDD.

Para futuras investigaciones, se recomienda implementar este diseño de predicción de la CDD en un contexto real con usuarios y datos no simulados. Esta evaluación permitirá estimar y comparar con mayor precisión las habilidades reales de los docentes, brindando información valiosa para la toma de decisiones sobre las necesidades formativas.

En otro orden de cosas, el modelo propuesto podría arrojar información para facilitar la propuesta de itinerarios personalizados de aprendizaje (De Benito et al., 2020) para que además de predecir los niveles de competencia digital, pueda generar recomendaciones personalizadas de aprendizaje en base a las predicciones de la CDD, lo que permitiría, entre otras cosas, una mayor flexibilización del proceso de enseñanza-aprendizaje y su adaptación a las características personales del estudiante así como a la propuesta de itinerarios centrados en mejorar la autonomía del estudiante y aumentar su autonomía. Estos itinerarios, con la ayuda del modelo de ML generado, se podría ajustar a los distintos estilos de aprendizaje, a las necesidades específicas de cada estudiante, así como a otros factores relacionados con el aprendizaje como la motivación, la autonomía, la personalización, entre otros). En este caso, estos itinerarios se caracterizarían por su carácter flexible (Salinas & Agudelo, 2016; Salinas & de Benito Crosetti, 2020). En cualquier caso, es importante señalar que la CDD es un factor determinante para el diseño e implementación de estrategias didácticas centradas en la flexibilización, en especial si se trata de formación en entornos virtuales, en los que el dominio de la competencia tecnológica se convierte en un elemento clave.

6. REFERENCIAS

- Bartolomé, A., Castañeda, L., & Adell, J. (2018). Personalisation in educational technology: the absence of underlying pedagogies. *International Journal of Educational Technology in Higher Education*, 15(1). <https://doi.org/10.1186/s41239-018-0095-0>
- Bearman, M., & Ajjawi, R. (2023). Learning to work with the black box: Pedagogy for a world with artificial intelligence. *British Journal of Educational Technology*, 54(5), 1160–1173. <https://doi.org/10.1111/bjet.13337>
- Belmonte, J. L., Segura-Robles, A., Moreno-Guerrero, A. J., & Parra-González, M. E. (2020). Machine learning and big data in the impact literature. A bibliometric review with scientific mapping in web of science. *Symmetry*, 12(4). <https://doi.org/10.3390/SYM12040495>
- 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 Investigacion Educativa*, 27(92), 185–208. https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-66662022000100185
- 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., Romero-Tena, R., Barroso-Osuna, J., & Palacios-Rodríguez, A. (2020). Marcos de Competencias Digitales Docentes y su adecuación al profesorado universitario y no universitario. *RECIE. Revista Caribeña de Investigación Educativa*, 4(2), 137–158. <https://doi.org/10.32541/recie.2020.v4i2.pp137-158>
- 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>
- Dai, Y., Liu, A., Qin, J., Guo, Y., Jong, M. S. Y., Chai, C. S., & Lin, Z. (2022). Collaborative construction of artificial intelligence curriculum in primary schools. *Journal of Engineering Education*, October 2022, 23–42. <https://doi.org/10.1002/jee.20503>
- De Benito, B., Moreno García, J., & Villatoro Moral, S. (2020). Entornos tecnológicos en el codiseño de itinerarios personalizados de aprendizaje en la enseñanza superior. *EduTec. Revista Electrónica de Tecnología Educativa*, 74, 73–93. <https://doi.org/10.21556/edutec.2020.74.1843>
- 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*, 0(1), 44–59. <https://doi.org/10.6018/riite2016/260631>
- Denys, B., & Klimczuk, B. (2022). *International Cooperation Towards Digital Transformation and Digital Ecosystems in Education*. 589–593.

- Dúo Terrón, P., Moreno Guerrero, A. J., López Belmonte, J., & Marín Marín, J. A. (2023). Inteligencia Artificial y Machine Learning como recurso educativo desde la perspectiva de docentes en distintas etapas educativas no universitarias. *Revista Interuniversitaria de Investigación En Tecnología Educativa*, 58–78. <https://doi.org/10.6018/riite.579611>
- Elliot, Jaime; Gorichon, Solange; Irigoin, María; Maurizi, M. R. (2011). *Competencias y Estándares TIC para la Profesión Docente*. 98.
- Esquivel Gámez, I. (2014). Los Modelos Tecno-Educativos, revolucionando el aprendizaje del siglo XXI. In *Nucl. Phys.* (Vol. 13, Issue 1). https://www.researchgate.net/publication/280301257_Los_Modelos_Tecno-Educativos_revolucionando_el_aprendizaje_del_siglo_XXI
- Flores, N., Castelán, V., & Zamora, M. (2021). Evaluación del perfil del profesorado a partir de los atributos del desempeño docente. *Revista Innova Educación*, 3(3), 53–72. <https://doi.org/10.35622/j.rie.2021.03.003>
- Forero-Corba, W., & Bennasar, F. N. (2024). Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: una revisión sistemática. *RIED-Revista Iberoamericana de Educacion a Distancia*, 27(1), 209–253. <https://doi.org/10.5944/ried.27.1.37491>
- Forero-Corba, W., & Negre Bennasar, F. (2024). Techniques and applications of Machine Learning and Artificial Intelligence in education: a systematic review. *RIED-Revista Iberoamericana de Educacion a Distancia*, 27(1), 209–253. <https://doi.org/10.5944/ried.27.1.37491>
- García Tamarit, C. O. N. S. U. E. L. O., Perochena González, P. A. O. L. A., & Orcos Palma, L. A. R. A. (2021). The design and validation of an instrument for assessing undergraduate dissertations. *Bordon. Revista de Pedagogia*, 73(2), 79–96. <https://doi.org/10.13042/Bordon.2021.89015>
- 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>
- Gisbert, M., & Lázaro, J. (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. *EDUTEC Revista Electrónica de Tecnología Educativa.*, 0(63), 1–14. <https://doi.org/10.21556/edutec.2018.63.1091>
- 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 Pedagogia*, 74(4), 85–102. <https://doi.org/10.13042/Bordon.2022.94154>
- 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*, 13(11), 727–734. <https://doi.org/10.14569/IJACSA.2022.0131184>
- INTEF. (2017). *MARCO COMÚN DE COMPETENCIA DIGITAL DOCENTE*.

International Society for Technology in Education. (2019). *ISTE Standards*.

López, R., Avello, R., Palmero, D. E., Sánchez, S., & Quintana, M. (2019). Validation of instruments as a guarantee of credibility in scientific research. *Revista Cubana de Medicina Militar*, 48(2), 441–450.

Lucas, M., Bem-Haja, P., Siddiq, F., Moreira, A., & Redecker, C. (2021). The relation between in-service teachers' digital competence and personal and contextual factors: What matters most? *Computers and Education*, 160(October 2020).
<https://doi.org/10.1016/j.compedu.2020.104052>

Mantilla Contreras, M. A. (2022). *MODELO DE FORMACIÓN PARA EL DESARROLLO DE COMPETENCIAS DIGITALES EN DOCENTES DE UNA UNIVERSIDAD DEL NORORIENTE COLOMBIANO*. Universidad de les Illes Balears.

Ministerio de Educación Nacional. (2013). Competencias TIC Para el Desarrollo Profesional Docente. In *Imprenta Nacional* (Oficina de, Vol. 82).

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 la Naciones Unidas. (2018). La Agenda 2030 y los Objetivos de Desarrollo Sostenible Una oportunidad para América Latina y el Caribe Gracias por su interés en esta publicación de la CEPAL. In *Publicación de las Naciones Unidas*.

Pérez-Escoda, A., Iglesias-Rodríguez, A., Meléndez-Rodríguez, Lady, & Berrocal-Carvajal, V. (2021). Competencia digital docente para la reducción de la brecha digital: Estudio comparativo de España y Costa Rica. *Tripodos*, 46, 77–96.
<https://doi.org/10.51698/tripodos.2020.46p77-96>

Prendes Espinosa, M. ^a P., Solano Fernández, I. M., Serrano Sánchez, J. L., González Calatayud, V., & Román García, M. ^a del M. (2018). Entornos Personales de Aprendizaje para la comprensión y desarrollo de la Competencia Digital: análisis de los estudiantes universitarios en España. *Educatio Siglo XXI*, 36(2 Julio), 115.
<https://doi.org/10.6018/i/333081>

Ramírez Martínez, J. L. (2019). El proceso de elaboración y validación de un instrumento de medición documental. *Acción y Reflexión Educativa*, 44, 50–63.

Redecker, C. (2020). Marco Europeo para la Competencia Digital de los Educadores: DigCompEdu. In *Secretaría General Técnica del Ministerio de Educación y Formación Profesional de España (Original publicado en 2017)*.

Salas-Pilco, S. Z., Xiao, K., & Hu, X. (2022). Artificial Intelligence and Learning Analytics in Teacher Education: A Systematic Review. *Education Sciences*, 12(8).
<https://doi.org/10.3390/educsci12080569>

Salinas Ibáñez, J. M., & Agudelo Velásquez, O. L. (2016). Itinerarios flexibles de aprendizaje y mapas conceptuales: un abánico de posibilidades para todos los niveles educativos. *Proc. of the Seventh Int. Conference on Concept Mapping*, Tabla 1.


- Salinas Ibáñez, J. M., & de Benito Crosetti, B. L. (2020). Construcción de itinerarios personalizados de aprendizaje mediante métodos mixtos. *Comunicar*, 65, 31–42. <https://doi.org/https://doi.org/10.3916/C65-2020-03>
- Salmerón Majadas, S. (2018). *A Methodological Approach based on Machine Learning to Generate a Multimodal User's Affective State Model in Adaptive Educational Systems*.
- Silva, J., Usart, M., & Lázaro-Cantabrana, J. L. (2019). Teacher's digital competence among final year Pedagogy students in Chile and Uruguay. *Comunicar*, 27(61), 31–40. <https://doi.org/10.3916/C61-2019-03>
- Suárez-Guerrero, C., Rivera-Vargas, P., & Rebour, M. (2020). Preguntas educativas para la tecnología digital como respuesta. *EduTec. Revista Electrónica de Tecnología Educativa*, 73, 7–22. <https://doi.org/10.21556/edutec.2020.73.1733>
- 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>
- Touron, J., Martin, D., Navarro Asencio, E., Pradas, S., & Inigo, V. (2018). Validation de constructo de un instrumento para medir la competencia digital docente de los profesores (CDD). *Revista Espanola de Pedagogia*, 75(269), 25–54. <https://doi.org/10.22550/REP76-1-2018-02>
- UNESCO. (2019). *CONSENSO DE BEIJING sobre la inteligencia artificial y la educación*. 26–39. <https://unesdoc.unesco.org/ark:/48223/pf0000368303?posInSet=3&queryId=N-EXPLORE-e2652983-c3e5-4aba-9a2e-13341d1392aa>
- UNESCO. (2021). Marco de competencias docentes en materia de TIC. In *UNESCO Publishing*.

Para citar este artículo:

Forero-Corba, W., y Negre Bennasar, F. 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>

7. ANEXOS

7.1. Anexo I. Niveles por competencias TIC



Nota. Tomado y adaptado de Ministerio de Educación Nacional (2013)

7.2. Anexo II. Rúbrica Competencia TIC docente

La siguiente rúbrica evalúa el nivel de la competencia digital docente en Colombia (Mantilla Contreras, 2022).

En la rúbrica aparecen descriptores organizados en cuatro niveles de competencia digital: Nivel Principiante (N1), Nivel Medio (N2), Nivel Experto (N3) y Nivel Transformador (N4). Debe marcar solo uno de los niveles en los que se encuentra.

Competencia Pedagógica	
Descriptor 1.1. Planificación docente y Competencia Digital	
N1: Planifica actividades de (EA) donde contempla el uso de las tecnologías digitales.	
N2: Incorpora en la planificación didáctica: la búsqueda, tratamiento, almacenamiento y difusión de la información digital en diferentes formatos.	
N3: Incorpora en la planificación didáctica el buen uso de las tecnologías digitales orientadas hacia al manejo pertinente de información, la publicación de productos y el trabajo colaborativo.	
N4: Diseña actividades que favorecen el desarrollo de competencias (transversales, orientadas al trabajo autónomo y colaborativo) que impliquen habilidades complejas: resolver problemas, inferir, comunicar..., donde se haga un uso especializado de las tecnologías digitales.	
Descriptor 1.2. Las tecnologías digitales como facilitadoras del aprendizaje	
N1: Utiliza herramientas digitales de apoyo en el aula para la realización de actividades de (EA).	
N2: Desarrolla actividades con los estudiantes que explican la resolución de problemas de forma colaborativa mediante el uso de recursos tecnológicos digitales.	
N3: Realiza actividades con los estudiantes que implican: el análisis de un problema en grupo, la propuesta de soluciones alternativas, la negociación de los resultados y su publicación haciendo uso complejo de los recursos tecnológicos digitales.	
N4: Estimula el aprendizaje autónomo y el trabajo colaborativo mediante procesos de investigación que conducen a la transformación y creación de conocimientos haciendo uso de recursos tecnológicos digitales.	
Descriptor 1.3. Estrategias metodológicas para la integración de las TIC	
N1: Reconoce las orientaciones de la unidad académica para la incorporación de las tecnologías digitales en el aula y las tiene en cuenta en sus programaciones didácticas.	
N2: Desarrolla actividades donde incorpora los recursos digitales en función de las orientaciones metodológicas y de los recursos de los que dispone la institución.	
N3: Incorpora los recursos digitales en actividades significativas (funcionales, transversales y que favorecen la autonomía) que implican el uso de las tecnologías digitales para construir y compartir el conocimiento.	
N4: Propone nuevas estrategias metodológicas innovadoras y sirve de modelo docente para la integración de las TIC.	
Descriptor 1.4. Práctica pedagógica	
N1: Utiliza las evaluaciones de los estudiantes para reflexionar acerca de las estrategias pedagógicas mediadas por TIC llevadas al aula.	
N2: Implementa en las prácticas pedagógicas estrategias mediadas por TIC teniendo en cuenta disposiciones de la unidad académica que se han obtenido a partir de la evaluación entre pares.	
N3: Diseña ambientes virtuales de aprendizaje para la institución que surgen de la reflexión de su práctica de aula.	
N4: Transforma sus prácticas pedagógicas a partir de investigaciones de la reflexión de su práctica pedagógica.	

Competencia Tecnológica	
Descriptor 2.1. Ambientes de aprendizaje y espacios con tecnologías digitales	
N1: Utiliza las tecnologías digitales de aula: Pizarra digital interactiva (PDI), dispositivos fijos y móviles, en función de cada situación de (EA).	
N2: Adecua las actividades de (EA) a partir de la incorporación de las tecnologías digitales en los espacios académicos disponibles en la unidad académica.	
N3: Modifica los espacios de (EA) con tecnologías digitales para mejorar y optimizar la infraestructura disponible a partir de unos criterios institucionales.	
N4: Utiliza herramientas digitales especializadas para diseñar ambientes virtuales innovadores que favorecen espacios de (EA).	
Descriptor 2.2. Infraestructuras tecnológicas digitales.	
N1: Hace un uso responsable de los espacios y tecnologías digitales, utilizando un protocolo para resolver incidencias.	
N2: Incorpora a su práctica innovaciones haciendo un uso responsable de los espacios y tecnologías digitales, evaluando los riesgos de su implementación.	
N3: Resuelve incidencias que pueden surgir de la implementación de innovaciones o de la utilización de las tecnologías digitales y hace propuestas de mejora para promover su utilización.	
N4: Gestiona el uso de las tecnologías digitales y promueve el diseño de recursos para brindar las orientaciones necesarias para acceder a la infraestructura tecnológica y resolver los problemas.	
Descriptor 2.3. Acceso libre a la información, creación y difusión de material didáctico con licencias abiertas.	
N1: Comparte materiales didácticos elaborados y distribuidos en abierto en la red.	
N2: Elabora materiales didácticos abiertos y los comparte en la red siguiendo un estándar que facilite la búsqueda y accesibilidad.	
N3: Organiza los Recursos Educativos Abiertos (REA) por tipo y áreas en función de las necesidades de la unidad académica.	
N4: Potencia el uso de (REA) mediante la creación y/o difusión de repositorios abiertos de materiales didácticos.	
Descriptor 2.4. Entorno personal de aprendizaje (PLE)	
N1: Utiliza diferentes aplicaciones de escritorio y web para gestionar los contenidos del aula y acceder a la información.	
N2: Configura su (PLE) utilizando herramientas digitales para el aprendizaje, fuentes de información y red personal de aprendizaje.	
N3: Colabora con los docentes de la unidad académica en la creación de sus (PLE).	
N4: Asesora en el uso de los (PLE) en la unidad académica.	
Descriptor 2.5. Gestión de tecnologías digitales y aplicaciones.	
N1: Identifica los espacios con tecnologías digitales, selecciona los recursos y las herramientas existentes para el trabajo en el aula.	
N2: Utiliza de manera responsable y segura, los espacios, recursos y herramientas adecuadas para las diferentes situaciones de (EA).	
N3: Combina el uso de diferentes tecnologías digitales e incorpora innovaciones en función de su potencialidad analizando de forma reflexiva el rendimiento de los estudiantes a partir de su utilización.	
N4: Investiga situaciones de (EA) basadas en la utilización de los espacios y tecnologías digitales e innova a partir de los resultados obtenidos.	
Descriptor 2.6. Ética y seguridad	
N1: Respeta los derechos de autor en sus materiales docentes y utiliza las tecnologías digitales personales de forma responsable y segura.	
N2: Fomenta el uso ético de las tecnologías digitales siendo un referente durante las actividades con los estudiantes.	
N3: Sirve de referente para otros profesionales sobre el uso responsable y seguro de las tecnologías digitales.	
N4: Promueve estudios acerca del uso responsable, ético y seguro de las tecnologías digitales, quedan respuesta a las necesidades y fomenten soluciones novedosas.	

Competencia Comunicación	
Descriptor 3.1. Comunicación, difusión y transferencia del conocimiento	
N1: Utiliza herramientas digitales para comunicarse y compartir sus conocimientos con otros docentes.	
N2: Gestiona recursos abiertos en red para publicar sus experiencias y compartirlas.	
N3: Capacita docentes, mediante actividades reconocidas por la institución, en el uso de las tecnologías digitales para compartir y crear conocimientos.	
N4: Sirve de referente en el uso de recursos tecnológicos para difundir y compartir su conocimiento, transformando la institución educativa en una unidad académica de innovación al servicio de la comunidad.	
Descriptor 3.2. Gestión de contenidos digitales	
N1: Accede y comenta los contenidos distribuidos en diferentes espacios digitales.	
N2: Utiliza los espacios digitales de la unidad académica como editor de alguno de ellos con el objetivo de compartir conocimientos y experiencias.	
N3: Utiliza un espacio digital propio como medio para publicar y difundir su conocimiento profesional y hacer participar a la comunidad educativa.	
N4: Gestiona espacios virtuales para difundir el conocimiento colectivo y para fortalecer la comunicación y la interacción entre los miembros de la comunidad educativa.	
Descriptor 3.3. Colaboración mediante herramientas digitales	
N1: Orienta a nivel de aula actividades de (EA) enfocadas a la colaboración mediante la creación de documentos compartidos que fortalecen el trabajo en equipo.	
N2: Utiliza las tecnologías digitales con los estudiantes en situaciones de (EA) para elaborar productos colaborativos a través de canales digitales diversos.	
N3: Capacita a los docentes de la unidad académica o institución en el uso de medios digitales de colaboración.	
N4: Utiliza las herramientas digitales de colaboración para investigar acerca de la usabilidad para favorecer procesos de (EA), compartiendo los resultados a través de redes profesionales.	
Descriptor 3.4. Comunidades de aprendizaje virtuales: formales, no formales e informales	
N1: Utiliza materiales docentes compartidos en red para la actividad académica en el aula.	
N2: Utiliza el aprendizaje en red como medio de formación permanente y promueve la participación de estudiantes en comunidades virtuales.	
N3: Promueve la participación de estudiantes en comunidades virtuales como estrategia de aprendizaje colaborativo y fomenta el aprendizaje en red entre los miembros de la unidad académica.	
N4: Gestiona un ecosistema de aprendizaje digital entre los miembros de la unidad académica y otras instituciones en la consolidación de comunidades y/o redes de aprendizaje interinstitucionales.	

Competencia Gestión	
Descriptor 4.1. Evaluación, tutoría y seguimiento de los estudiantes	
N1: Utiliza recursos digitales para la tutoría y seguimiento de los estudiantes (registrar asistencia y valoraciones, enviar mensajes, ...)	
N2: Utiliza escenarios educativos digitales para evaluar, hacer seguimiento al aprendizaje de los estudiantes y mejorar los procesos de realimentación.	
N3: Utiliza recursos digitales para compartir la evaluación y el seguimiento de los estudiantes con otros profesionales de la unidad académica (facultad, departamento, escuela, instituto, corporación, carrera, posgrado, ...), para mejorar los resultados teniendo en cuenta el despliegue de estrategias didácticas digitales.	
N4: Gestiona y utiliza recursos digitales (entornos, portafolios digitales, ...) para hacer el seguimiento escolar, la evaluación de los estudiantes a nivel de la unidad académica y utilizar los resultados para investigar la incorporación de las TIC en los procesos de (EA).	
Descriptor 4.2. Evaluación y recuperación de contenidos digitales	
N1: Reconoce las diferentes fuentes de información y contenidos digitales para la docencia y almacena los recursos disponibles.	
N2: Orienta en su práctica de aula, la valoración de contenidos digitales y los organiza	

Competencia Gestión	
considerando diferentes tipos de almacenamiento.	
N3: Evalúa la calidad de los recursos y diferencia las licencias que permiten reutilizarlos para incorporarlos a nivel de aula y la unidad académica.	
N4: Capacita a los docentes de la institución para evaluar de manera crítica las fuentes de información, perfiles académicos y comunidades a las cuales pertenece.	
Descriptor 4.3. Identidad digital de la institución	
N1: Conoce la identidad digital de la unidad académica, la necesidad de respetar los modelos documentales y protocolos relativos a la identificación visual.	
N2: Incorpora a sus documentos y espacios virtuales la identificación visual de la unidad académica e institucional.	
N3: Participa en el mejoramiento de la imagen institucional en los espacios virtuales de la unidad académica.	
N4: Transforma los espacios virtuales de la unidad académica velando por transmitir una identidad digital de la propia institución.	
Descriptor 4.4. Gestión de la Institución	
N1: Identifica elementos de la gestión de la unidad académica, que pueden ser mejorados a partir de la incorporación de las tecnologías digitales, en las diferentes actividades realizadas.	
N2: Adopta políticas de la institución en beneficio de la unidad académica, para el uso de tecnologías digitales que contribuyen a la dinamización de procesos de gestión.	
N3: Propone acciones para optimizar la gestión institucional a partir del uso de las tecnologías digitales que permiten integrar los procesos y hacerlos más efectivos.	
N4: Lidera acciones para optimizar los procesos integrados a la gestión institucional desde el uso de las tecnologías digitales.	
Descriptor 4.5. Formación Permanente	
N1: Participa en actividades de formación profesional que son orientadas por la unidad académica, reconocidas por la administración educativa y están relacionadas con las tecnologías digitales.	
N2: Gestiona su plan de formación de manera permanente, de acuerdo a las necesidades de desarrollo profesional, mediante actividades de educativas que están relacionadas con las tecnologías digitales y la innovación educativa, y son reconocidas por la administración educativa.	
N3: Transforma su práctica docente, mediante la incorporación de las tecnologías digitales a la misma, incorporando los conocimientos obtenidos en las actividades de formación: "transferencia de la formación".	
N4: Participa como formador en actividades de capacitación permanente del profesorado relacionadas con las tecnologías digitales.	
Descriptor 4.6. Participación ciudadana	
N1: Participa en los diferentes escenarios digitales promoviendo acciones socialmente responsables.	
N2: Realiza actividades pedagógicas que favorecen el empoderamiento de las tecnologías y promoción de una ciudadanía digital en los estudiantes.	
N3: Promueve actividades de capacitación a en la unidad académica con el propósito de promover la participación responsable en el mundo digital.	
N4: Desarrolla proyectos con otros profesionales de la comunidad educativa hacia la participación y promoción de la ciudadanía digital.	
Descriptor 4.7. Inclusión digital	
N1: Potencia el acceso y uso de las tecnologías digitales por parte de todos los estudiantes con la intención de compensar las desigualdades.	
N2: Participa en la organización de la atención a la diversidad de la unidad académica ejerciendo acciones para compensar las desigualdades a nivel de acceso y uso de las tecnologías digitales.	
N3: Promueve la utilización de los espacios y recursos tecnológicos digitales de la unidad académica mediante la participación en acciones orientadas a la compensación de las desigualdades.	
N4: Capacita a los integrantes de la unidad académica con acciones orientadas a la generalización del uso, la gestión y la difusión de buenas prácticas en el uso de las tecnologías digitales.	

Competencia Investigativa	
Descriptor 5.1. Tratamiento de la información y creación de conocimiento	
N1: Enseña a realizar búsquedas de información accediendo a diferentes fuentes de diversa tipología, teniendo en cuenta procedimientos definidos.	
N2: Enseña a utilizar fuentes de información de diferente tipología atendiendo a criterios de calidad, veracidad y pertinencia.	
N3: Enseña a clasificar, ordenar y seleccionar la información desde diferentes fuentes aplicando criterios de calidad, veracidad y pertinencia, promoviendo una valoración crítica de los recursos digitales.	
N4: Enseña a crear y transformar la información en conocimiento, que previamente se ha almacenado y recuperado, siguiendo un sistema que le permita hacer un uso compartido.	
Descriptor 5.2. Proyectos de incorporación de las tecnologías digitales	
N1: Sigue las directrices acordadas a nivel de unidad académica sobre el uso de las tecnologías digitales en la docencia.	
N2: Forma parte activa de los equipos de la unidad académica y aporta su experiencia y conocimientos sobre las tecnologías digitales.	
N3: Lidera un equipo de trabajo de la facultad o unidad académica haciéndose cargo de gestionar la utilización de las tecnologías digitales en las prácticas pedagógicas.	
N4: Coordina proyectos interdisciplinarios o interinstitucionales en torno a la incorporación de las tecnologías digitales en la docencia.	
Descriptor 5.3. Liderazgo en el uso de las tecnologías digitales	
N1: Utiliza las tecnologías digitales con los estudiantes haciendo de referente en cuanto a su uso.	
N2: Integra las tecnologías digitales a la docencia y comparte experiencias con los colegas, siendo un referente de incorporación TIC.	
N3: Coordina el uso de las tecnologías siendo un modelo de curación de contenidos y recursos digitales a nivel de la unidad académica.	
N4: Asesora a la unidad académica en la utilización y gestión de las tecnologías digitales y difunde la experiencia y las buenas prácticas.	
Descriptor 5.4. Identidad y presencia digital	
N1: Usa la identificación digital profesional en las comunicaciones y mantiene su perfil actualizado en los espacios virtuales de la unidad académica.	
N2: Tiene un perfil digital y un currículum profesional actualizado online.	
N3: Utiliza las redes sociales y profesionales como medio de comunicación e interacción profesional, que le facilita conectarse con otros investigadores.	
N4: Utiliza las redes para el desarrollo profesional en la divulgación de resultados de las investigaciones y promueve el uso e importancia a los miembros de la unidad académica.	