

Modelo de predicción para evaluar la adaptabilidad de los estudiantes en educación virtual: Un enfoque basado en Machine Learning

Predictive model for assessing student adaptability in e-learning: A machine learning based approach

Nila Navarro

Dirección de investigación, innovación y vinculación con el medio
Universidad Iberoamericana de Panamá

David, Panamá

Direccion.investigacion@unibero.ac.pa

Resumen — Este estudio emplea modelos de Machine Learning (ML) para predecir la adaptabilidad de los estudiantes en entornos de educación virtual. A través de variables como el género, nivel educativo, condiciones financieras y acceso a tecnología, se construyó un modelo predictivo que clasifica a los estudiantes según su capacidad de adaptación. El modelo Random Forest (RF) alcanzó una precisión del 88.8%, proporcionando herramientas útiles para que educadores y administradores anticipen necesidades y ajusten estrategias pedagógicas, promoviendo una experiencia de aprendizaje más eficiente y personalizada.

Palabras Clave – Aprendizaje automático; Adaptabilidad estudiantil; Educación virtual; Análisis de datos, Bosques aleatorios.

Abstract — This study uses machine learning (ML) models to predict the adaptability of students in virtual education environments. Using variables such as gender, education level, financial conditions and access to technology, a predictive model was built that classifies students according to their adaptability. The random Forest (RF) model achieved an accuracy of 88.8%, providing useful tools for educators and administrators to anticipate needs and adapt pedagogical strategies, promoting a more efficient and personalized learning experience.

Keywords – Machine Learning; Learning to adapt; e-Learning; Data analysis, Random Forest.

I. INTRODUCCIÓN

Antes de la pandemia de la COVID-19, la educación tradicional se basaba principalmente en clases presenciales, con un enfoque cara a cara entre estudiantes y profesores. Este modelo ofrecía una interacción directa que permitía a los educadores evaluar, en tiempo real, las necesidades de los estudiantes y adaptar los métodos de enseñanza a su ritmo de aprendizaje [1], [2]. Sin embargo, la crisis sanitaria global que comenzó en 2020 obligó a la mayoría de los países a adoptar el aprendizaje en línea como una medida urgente para garantizar la continuidad educativa. En ese contexto, las instituciones educativas tuvieron que implementar plataformas digitales, herramientas tecnológicas y metodologías a distancia para mantener la enseñanza [3], [4], [5], [6].

La transición a la educación virtual no fue sencilla. Muchos

estudiantes se encontraron con dificultades debido a la falta de acceso adecuado a tecnologías, conexiones de internet inestables, o la falta de experiencia en el uso de plataformas digitales. Este cambio, aunque necesario, reveló la brecha de adaptabilidad que existía entre los estudiantes. Mientras algunos se ajustaron rápidamente al nuevo entorno de aprendizaje en línea, otros enfrentaron desafíos significativos [7], [8].

La educación virtual se ha consolidado como una modalidad permanente en muchos sistemas educativos, incluso después de la pandemia. Las instituciones buscan mejorar la calidad y efectividad de la educación a distancia, creando entornos de aprendizaje más inclusivos y personalizados. Para lograrlo, es esencial entender los factores que afectan la adaptabilidad de los estudiantes a los entornos virtuales.

¿Qué características demográficas, tecnológicas y socio-económicas determinan si un estudiante podrá integrarse con éxito en una plataforma educativa digital? Esta es la pregunta que nos motiva a explorar el uso de modelos de predicción para evaluar el nivel de adaptabilidad de los estudiantes en entornos de educación en línea, con el fin de implementar estrategias que mejoren su experiencia y rendimiento académico [9].

Este estudio proporciona un enfoque innovador para evaluar la adaptabilidad de los estudiantes en entornos de educación virtual mediante el uso de modelos de predicción basados en Machine Learning. Al analizar diversas variables como el género, el nivel educativo, las condiciones financieras y el acceso a la tecnología, se identifican patrones que permiten predecir cómo los estudiantes se ajustan a las plataformas de aprendizaje en línea. El aporte principal radica en ofrecer a las instituciones educativas una herramienta cuantitativa que facilite la identificación de estudiantes con alto y bajo nivel de adaptabilidad, permitiendo así la implementación de intervenciones personalizadas y estrategias de apoyo [10], [11].

II. MATERIALES Y MÉTODOS

A. Trabajos Relacionados

La Tabla 1 muestra trabajos relacionados que son relevantes para nuestro estudio, abordando áreas clave del aprendizaje au-

Identify applicable sponsor/s here. If no sponsors, delete this text box. (sponsors)

tomatizado y la personalización de la educación en línea, con enfoques y metodologías aplicables para mejorar la experiencia educativa y predecir el progreso académico de los estudiantes.

TABLA 1. TRABAJOS RELACIONADOS

Funcionalidad	Enfoque	Ref
Identificación automática de estilos de aprendizaje y análisis de retroalimentación.	Uso de FSLSM, fuzzy logic y deep learning para clasificar estilos de aprendizaje y LDA para análisis de sentimientos.	[12]
Adaptación personalizada basada en múltiples factores.	Uso de k-means clustering y Support Vector Regression (SVR) para personalizar rutas de aprendizaje según datos previos y preferencias.	[13]
Evaluación de factores clave en el aprendizaje en línea.	Minería de datos, modelos Lasso y Gradient Boosting con Shapley Values para identificar variables críticas.	[14]
Creación de modelos predictivos del progreso académico.	Aplicación de regresión logística, máquinas de soporte vectorial y redes neuronales con una precisión del 75%.	[15]

Este estudio aporta un enfoque novedoso al predecir la adaptabilidad estudiantil a entornos virtuales, integrando variables demográficas, tecnológicas y socioeconómicas. A diferencia de investigaciones previas centradas en estilos de aprendizaje o rendimiento académico, este trabajo clasifica a los estudiantes en niveles de adaptabilidad usando un modelo Random Forest, con una precisión del 88.8%. Esto permite interpretar las variables clave y ofrece a las instituciones educativas una herramienta para anticipar necesidades y diseñar estrategias pedagógicas personalizadas.

B. Metodología

El propósito de este estudio fue analizar los factores que influyen en la adaptabilidad de los estudiantes a los entornos de educación virtual y desarrollar un modelo predictivo que permita evaluar esta adaptabilidad en función de diferentes características.

La metodología se estructuró en diversas etapas clave que guiarán la interpretación y el análisis de los resultados obtenidos:

Definición del Problema y Objetivos del Estudio: El primer paso fue identificar la necesidad de evaluar la adaptabilidad de los estudiantes en la educación virtual. La pregunta de investigación fue: ¿Qué factores influyen en la capacidad de los estudiantes para adaptarse a las plataformas de aprendizaje en línea? Los objetivos se centraron en clasificar a los estudiantes según su nivel de adaptabilidad, utilizando variables sociodemográficas y tecnológicas.

Selección de Variables y Recopilación de Datos: Se seleccionaron variables como género, edad, nivel educativo, acceso a internet, y dispositivos utilizados.

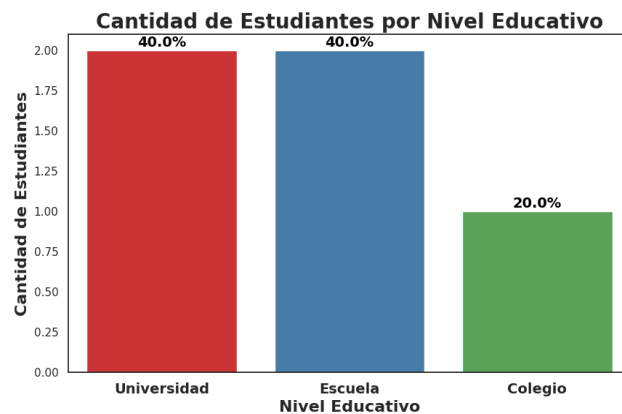


Figura 1. Edad promedio según el nivel educativo

La figura 1 muestra la variación de la edad promedio según el nivel educativo:

- Escuela: Edad promedio más baja.
- Colegio: Edad promedio intermedia.
- Universidad: Edad promedio más alta.

Este análisis destaca la importancia del nivel educativo, relacionado con la edad, como una variable clave en la adaptación a entornos virtuales, ya que estudiantes más jóvenes requieren enfoques pedagógicos distintos a los de los universitarios. La figura 2 muestra la distribución de los tipos de internet utilizados, con un 57.7% de estudiantes usando datos móviles y un 42.3% usando WiFi. Este dato subraya la relevancia del acceso a la tecnología, ya que el tipo de conexión influye en la experiencia y adaptabilidad de los estudiantes en el aprendizaje virtual.

Distribución de tipos de Internet utilizados




Figura 2. Distribución de tipos de internet utilizados

Desarrollo del Modelo Predictivo: Con los datos obtenidos, se desarrolló un modelo de Machine Learning utilizando algoritmos de clasificación. Este modelo permitió predecir la adaptabilidad de los estudiantes con base en sus características.

Interpretación de Resultados: Finalmente, los resultados obtenidos del modelo se analizaron para identificar patrones clave que podrían ayudar a mejorar la experiencia de los estudiantes en plataformas de educación virtual, ofreciendo propuestas de intervención basadas en los hallazgos.

C. Fuente de datos

Para la realización de este estudio, se utilizó un conjunto de datos disponible en la plataforma Kaggle, propiedad de los siguientes autores: Md. Mahmudul Hasan Suzan, Nishat Ahmed Samrin, Al Amin Biswas y Md. Aktaruzzaman Pramanik. Este conjunto de datos se centró en evaluar el nivel de adaptabilidad de los estudiantes en entornos de educación virtual, y fue seleccionado debido a su relevancia y exhaustividad en cuanto a las variables relacionadas con el comportamiento de los estudiantes en el ámbito digital [16].

La fuente original del conjunto de datos se encuentra disponible en Kaggle, una plataforma pública reconocida por su contribución a la comunidad de análisis de datos y Machine Learning.

Conjunto de datos obtenido de Kaggle: <https://www.kaggle.com/datasets/mdmahmudulhasansuzan/students-adaptability-level-in-online-education>

D. Generación del modelo

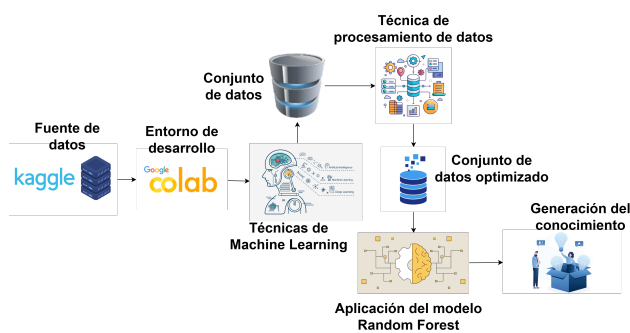


Figura 3. Lógica del modelo

La figura 3 muestra que el modelo tiene una precisión del 89%. La clase “Media Adaptabilidad” (1) es la mejor identificada, con un recall del 96%, indicando una alta capacidad de clasificación. La “Alta Adaptabilidad” (2) también tiene buenos resultados, mientras que la “Baja Adaptabilidad” (0) presenta un recall de 57%, lo que sugiere que algunos estudiantes fueron mal clasificados.

A continuación, explicaremos la lógica empleada en la creación del modelo.

Recolección de Datos: La primera etapa consistió en la recopilación de datos, los cuales fueron obtenidos a través de un dataset de acceso libre, como se mencionó previamente.

Preprocesamiento de Datos: En esta fase se realizó una limpieza y transformación de los datos para garantizar su calidad. Se eliminaron los valores faltantes y se codificaron las variables categóricas mediante el uso de label encoding para convertirlas en un formato adecuado para los modelos de Ma-

chine Learning. Además, se normalizaron algunas variables numéricas para mejorar la precisión del modelo.

División de los Datos: El conjunto de datos se dividió en dos partes: un conjunto de entrenamiento y un conjunto de prueba. Aproximadamente el 80% de los datos se utilizaron para entrenar el modelo, mientras que el 20% restante se destinó a la evaluación del rendimiento del modelo. Esta división se eligió debido a su simplicidad y eficiencia en comparación con la validación cruzada, especialmente cuando el conjunto de datos no es extremadamente pequeño. Al usar esta partición, se garantiza que el modelo tenga suficiente información para aprender y, al mismo tiempo, se preserva un conjunto independiente para evaluar su capacidad de generalización. Aunque la validación cruzada es útil para obtener estimaciones más robustas, este enfoque es adecuado cuando se busca una evaluación rápida y cuando los recursos computacionales o el tiempo son limitados.

Selección del Modelo: Se seleccionó el algoritmo de Random Forest Classifier para la clasificación, ya que es un modelo robusto que maneja eficientemente grandes volúmenes de datos y es capaz de manejar tanto variables categóricas como numéricas. Este modelo se entrenó utilizando las variables de entrada y se configuró con 100 estimadores para obtener una clasificación precisa.

Entrenamiento y Ajuste del Modelo: Se entrenó el modelo utilizando el conjunto de entrenamiento y se ajustaron los parámetros para optimizar la capacidad predictiva del algoritmo. Durante esta fase, se llevaron a cabo varias iteraciones para identificar los parámetros más adecuados y mejorar la precisión del modelo.

Evaluación del Modelo: Se evaluó el rendimiento del modelo utilizando el conjunto de prueba. La evaluación se realizó mediante métricas estándar como la precisión, recall, f1-score y la matriz de confusión. Los resultados obtenidos permitieron conocer la capacidad de predicción del modelo respecto a los distintos niveles de adaptabilidad de los estudiantes en el contexto de la educación virtual.

III. RESULTADOS

A. Técnicas de Preprocesamiento y Preparación de Datos

En este estudio, antes de aplicar el modelo de Machine Learning, fue fundamental realizar una serie de pasos de preprocesamiento de datos para asegurar que el conjunto de datos estuviera listo para el entrenamiento del modelo.

Estos pasos de preprocesamiento incluyen:

Carga y Exploración de los Datos: El primer paso fue cargar y explorar el conjunto de datos, que constaba de 16,870 registros y 14 columnas con características como género, edad, nivel educativo, condición financiera y duración de la clase, entre otras, proporcionando información sobre la adaptabilidad de los estudiantes a la educación en línea.

Manejo de Valores Faltantes: En algunos casos, ciertos valores en el conjunto de datos estaban ausentes. Para tratar con los valores faltantes, se utilizó una técnica de relleno o imputación (dependiendo del caso), o en algunos casos, se eliminó las filas que contenían valores faltantes, asegurando así que el modelo no tuviera datos incompletos.

Codificación de Variables Categóricas: El conjunto de datos contenía variables categóricas (como el género, nivel educativo, tipo de institución, etc.), que no podían ser utilizadas directamente por los algoritmos de Machine Learning. Para abordar esto, se aplicó la técnica de Codificación LabelEncoder, que transformó estas variables categóricas en valores numéricos. Por ejemplo:

- Género se transformó a 0 (hombre) y 1 (mujer).
- Nivel Educativo y otras variables de texto se convirtieron en valores numéricos que el modelo pueda procesar.

División en Conjunto de Entrenamiento y Conjunto de Prueba: Para entrenar y evaluar el modelo, el conjunto de datos se dividió en dos partes:

- **Conjunto de entrenamiento:** Representa el 80% de los datos, utilizado para entrenar el modelo y ajustar sus parámetros.
- **Conjunto de prueba:** El 20% restante de los datos se utilizó para evaluar el rendimiento del modelo, asegurando que este no estuviera sobre ajustado (overfitting).

De esta forma, el modelo tiene suficiente información para aprender y generalizar correctamente sin sobreajustarse a los datos de entrenamiento.

Escalado de Variables Numéricas: Algunas características numéricas, como la edad, duración de la clase y otros valores, podían tener rangos de magnitudes muy diferentes. Para normalizar estas características y evitar que algunas variables dominaran el modelo, se utilizó la técnica de escalado de variables, como el MinMaxScaler o StandardScaler, según fuera necesario.

B. Distribución de los datos para entrenamiento

El dataset inicial de 16,870 registros se dividió en los dos conjuntos (entrenamiento y prueba). Al dividir los datos en una proporción del 80% para entrenamiento y 20% para prueba, la distribución fue la siguiente:

- **Conjunto de Entrenamiento:** Aproximadamente 13,496 registros (80%).
- **Conjunto de Prueba:** Aproximadamente 3,374 registros (20%).

Esto garantiza que el modelo pueda aprender de una gran cantidad de datos, pero también se valida su capacidad para generalizar cuando se enfrenta a nuevos datos no vistos durante el entrenamiento.

C. Generación del modelo

El modelo se generó utilizando el algoritmo Random Forest Classifier. Este fue elegido debido a su capacidad para manejar datos complejos y diversos, como los presentes en este conjunto de datos.

Entrenamiento: Se dividió el conjunto de datos en dos partes: el conjunto de entrenamiento (80%) y el conjunto de prueba (20%). El modelo fue entrenado usando el conjunto de entrenamiento, que contiene las variables predictoras, mientras que la variable de estudio fue el nivel de adaptabilidad.

Ajuste del Modelo: Durante el entrenamiento, el modelo aprendió a identificar patrones en los datos y a predecir la adaptabilidad de los estudiantes en entornos virtuales.

Evaluación: Finalmente, se evaluó el rendimiento del modelo utilizando el conjunto de prueba. Se utilizó precisión, recall y f1-score para medir la efectividad del modelo en la clasificación de los niveles de adaptabilidad.

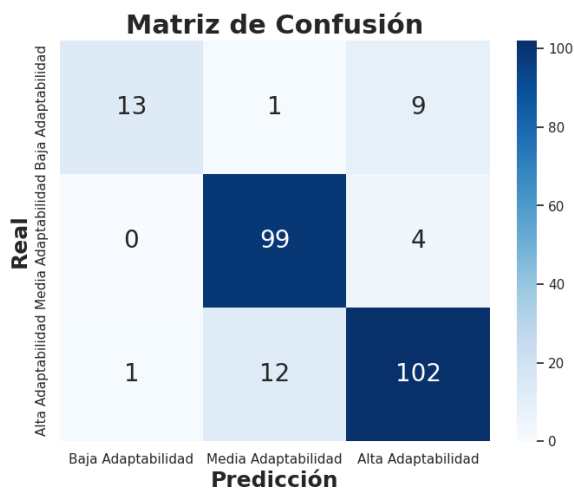


Figura 4. Matriz de confusión

La Figura 4 muestra la matriz de confusión generada durante la evaluación del modelo de clasificación. Esta matriz se utiliza para comparar las predicciones del modelo con las etiquetas reales en las tres clases analizadas: Baja Adaptabilidad, Media Adaptabilidad y Alta Adaptabilidad.

En términos de resultados, el modelo presenta la siguiente distribución:

Clase Baja Adaptabilidad:

- Predicciones correctas: 13.
- Predicciones incorrectas: 1 clasificado como Media Adaptabilidad y 9 clasificados como Alta Adaptabilidad.

Clase Media Adaptabilidad:

- Predicciones correctas: 99.
- Predicciones incorrectas: 4 clasificados como Alta Adaptabilidad, sin errores hacia Baja Adaptabilidad.

Clase Alta Adaptabilidad:

- Predicciones correctas: 102.
- Predicciones incorrectas: 1 clasificado como Baja Adaptabilidad y 12 clasificados como Media Adaptabilidad.

El modelo tiene un alto rendimiento para las clases Media y Alta Adaptabilidad, con 99 y 102 predicciones correctas, respectivamente. Sin embargo, la clase Baja Adaptabilidad tiene solo 13 predicciones correctas y presenta confusiones con la clase Alta Adaptabilidad (9 casos). Esto podría deberse a una desproporción en los datos o características poco diferenciadas

entre estas clases. La figura 5 muestra el reporte de clasificación para las tres clases de adaptabilidad: Baja, Media y Alta.

Clase	Precisión	Recall	F1-Score	Soporte
0	0.93	0.57	0.7	23
1	0.88	0.96	0.92	103
2	0.89	0.89	0.89	115
Exactitud	0.89	nan	nan	241
Promedio Macro	0.9	0.8	0.84	241
Promedio Ponderado	0.89	0.89	0.88	241

Figura 5. Reporte de precisión

La figura 5 refleja que el modelo tiene un rendimiento sólido en términos generales, con una precisión del 89%. La clase Media Adaptabilidad (1) es la mejor identificada, con un recall del 96%, lo que sugiere que el modelo tiene una alta capacidad para identificar correctamente a los estudiantes en esta categoría. La Alta Adaptabilidad (2) también tiene buenos resultados, mientras que la Baja Adaptabilidad (0) tiene un desempeño más bajo, con un recall de 57%, lo que sugiere que algunos estudiantes con baja adaptabilidad fueron mal clasificados.

IV. DISCUSIÓN

Este estudio ha demostrado la viabilidad de usar modelos de Machine Learning (ML) para predecir la adaptabilidad de los estudiantes en entornos de educación virtual, un ámbito que se ha vuelto crucial en el contexto educativo actual. Los resultados obtenidos a partir del modelo de Random Forest, con una precisión general de 88.80%, indican que la adaptabilidad de los estudiantes está influenciada por diversas variables, como el género, el nivel educativo, las condiciones financieras, y el acceso a tecnologías. Este hallazgo subraya la importancia de considerar múltiples factores en la evaluación de la disposición de los estudiantes para participar y aprovechar plataformas educativas en línea [17].

Uno de los puntos destacados es la capacidad del modelo para clasificar correctamente a los estudiantes en diferentes niveles de adaptabilidad. Esto puede ser especialmente útil para los educadores y administradores de plataformas educativas, ya que les permite anticipar las necesidades de los estudiantes con base en sus características y ajustar las estrategias de enseñanza de manera más personalizada [18], [19].

Aunque la precisión del modelo es alta, no es perfecta, lo que indica que hay variables no capturadas que podrían influir en la adaptabilidad. Además, la clasificación de algunos estudiantes en niveles bajos sugiere que podrían necesitar intervenciones específicas para superar obstáculos en la educación digital.

En cuanto a la aplicabilidad, este enfoque ofrece una herramienta valiosa para tomar decisiones informadas sobre cómo mejorar las experiencias de aprendizaje digital. Sin embargo, los resultados también destacan la importancia de un seguimiento continuo y la reevaluación de los modelos predictivos a medida que evoluciona la educación en línea y las condiciones de acceso a la tecnología cambian [20], [21].

V. CONCLUSIONES

Este estudio presenta un modelo de Machine Learning basado en Random Forest, con una precisión del 88.8%, para pre-

decir la adaptabilidad de los estudiantes en plataformas educativas virtuales. La investigación responde de manera directa a la pregunta planteada sobre qué características demográficas, tecnológicas y socioeconómicas determinan si un estudiante podrá integrarse con éxito en una plataforma educativa virtual. Los resultados obtenidos revelan que las principales características influyentes son el género, el nivel educativo, las condiciones financieras, y el acceso a tecnologías (incluyendo el tipo de dispositivo y la calidad de la conexión a internet). El género y el nivel educativo se correlacionan significativamente con la capacidad de los estudiantes para adaptarse a la educación virtual, ya que los estudiantes de ciertos niveles educativos tienden a tener mayor acceso a recursos digitales, mientras que el género puede influir en el tipo de interacción con las plataformas de aprendizaje. Las condiciones financieras también juegan un papel crucial, ya que los estudiantes con menores recursos económicos tienen más dificultades para acceder a tecnología de calidad, lo que limita su adaptabilidad. Finalmente, el tipo de conexión a internet y el dispositivo utilizado se muestran como factores determinantes: aquellos con acceso a conexiones rápidas y dispositivos adecuados tienen mayor capacidad para interactuar de manera efectiva con los contenidos y herramientas de las plataformas virtuales.

El concepto de adaptabilidad en este estudio se ha definido como la habilidad de los estudiantes para ajustarse eficazmente a un entorno de educación virtual, lo cual incluye no solo la capacidad técnica para usar las plataformas digitales, sino también la disposición y las habilidades cognitivas para gestionar el aprendizaje en línea de manera autónoma. En este sentido, los estudiantes con mayor acceso a recursos tecnológicos y mejor preparación educativa muestran mayores niveles de adaptabilidad.

En cuanto a las amenazas a la validez de la implementación, es importante señalar que, aunque el modelo ha mostrado una alta precisión, existen variables adicionales que no fueron incluidas en este estudio pero que podrían influir en la adaptabilidad de los estudiantes. Por ejemplo, la calidad del soporte emocional y social disponible para los estudiantes, así como factores externos como el ambiente familiar y la motivación personal, pueden tener un impacto significativo en la forma en que los estudiantes interactúan con las plataformas educativas. Además, dado que el modelo se basa en datos históricos, no se ha evaluado cómo las condiciones cambiantes de la tecnología y las políticas educativas podrían alterar la capacidad de adaptación de los estudiantes a largo plazo. La evolución continua de estas variables requiere una reevaluación periódica del modelo para mantener su validez.

En conclusión, este estudio ha identificado las características clave que determinan la adaptabilidad de los estudiantes a las plataformas educativas virtuales y ha proporcionado un marco útil para futuras investigaciones y aplicaciones en el diseño de estrategias pedagógicas más inclusivas. La implementación de este modelo puede ser valiosa para personalizar la experiencia de aprendizaje y asegurar una mayor equidad en el acceso y éxito de los estudiantes en entornos educativos digitales.

AGRADECIMIENTOS

Agradezco a la Universidad Iberoamericana de Panamá por su invaluable apoyo, recursos y ambiente académico que facili-

taron el desarrollo de este estudio. Su compromiso con la investigación y la innovación educativa ha sido fundamental para la realización de este trabajo.

REFERENCIAS BIBLIOGRÁFICA

- [1] A. P. Galván Cardoso and E. Siado Ramos, "Educación Tradicional: Un modelo de enseñanza centrado en el estudiante," *CIENCIAMATRIA, ISSN-e 2610-802X, ISSN 2542-3029, Vol. 7, N.º. 12, 2021, págs. 962-975*, vol. 7, no. 12, pp. 962–975, 2021, doi: 10.35381/cm.v7i12.457.
- [2] Caisso and Lucia, "Educación popular, educación tradicional: análisis etnográfico de un conflicto en un bachillerato popular," <http://journals.openedition.org/etnografica>, no. vol. 21 (2), pp. 341–364, Jun. 2017, doi: 10.4000/ETNOGRAFICA.4933.
- [3] T. N. Hohlfeld, A. D. Ritzhaupt, K. Dawson, and M. L. Wilson, "Educación en tiempos de pandemia (covid-19)," *Revista de la Universidad de La Salle*, vol. 1, no. 85, pp. 51–59, Oct. 2020, doi: 10.1016/J.COMPEDU.2017.05.017.
- [4] S. A. P. Peñuelas, L. I. C. Pierra, Ó. U. R. González, and O. I. G. Nogales, "Enseñanza remota de emergencia ante la pandemia Covid-19 en Educación Media Superior y Educación Superior," *Propósitos y Representaciones*, vol. 8, no. SPE3, pp. e589–e589, Sep. 2020, doi: 10.20511/PYR2020.V8NSPE3.589.
- [5] P. Valdivia Vizarreta and P. Valdivia Vizarreta, "Educación Superior: Pandemia COVID-19," *Revista Digital de Investigación en Docencia Universitaria*, vol. 14, no. 2, p. e1388, Dec. 2020, doi: 10.19083/RIDU.2020.1388.
- [6] P. A. Toledo, "Pandemia Covid-19: Educación a Distancia. O las Distancias en la Educación," *Revista internacional de educación para la justicia social*, 2020, [Online]. Available: www.rinace.net/riejs/revistas.uam.es/riejs
- [7] D. Schneckenberg, "El e-learning transforma la educación superior," *EDUCAR*, vol. 33, no. 0, pp. 143–156, Jan. 2004, doi: 10.5565/rev/educar.266.
- [8] Z. Carolina and N. Sánchez, "El e-learning como un recurso de desarrollo educativo," *Revista de investigación, administración e ingeniería*, 2018.
- [9] F. José and G. Peñalvo, "Estado actual de los sistemas e-learning," *Education in the Knowledge Society (EKS)*, vol. 6, no. 2, Jan. 2005, doi: 10.14201/EKS.18184.
- [10] X. Zhai *et al.*, "A Review of Artificial Intelligence (AI) in Education from 2010 to 2020," *Complexity*, vol. 2021, no. 1, p. 8812542, Jan. 2021, doi: 10.1155/2021/8812542.
- [11] F. Tahiru, "AI in Education: A Systematic Literature Review," *Cases of Information Technology*, vol. 23, no. 1, pp. 1–20, 2021, doi: 10.4018/JCIT.2021010101.
- [12] T. Hussain, L. Yu, M. Asim, A. Ahmed, and M. A. Wani, "Enhancing E-Learning Adaptability with Automated Learning Style Identification and Sentiment Analysis: A Hybrid Deep Learning Approach for Smart Education," *Information 2024, Vol. 15, Page 277*, vol. 15, no. 5, p. 277, May 2024, doi: 10.3390/INFO15050277.
- [13] A. Ezzaim and A. Aqqal, "Development, Implementation, and Evaluation of a Machine Learning-Based Multi-Factor Adaptive E-Learning System," 2024. [Online]. Available: <https://www.researchgate.net/publication/383602925>
- [14] N. A. McIntyre, "Accelerating online learning: Machine learning insights into the importance of cumulative experience, independence, and country setting," *Computers and Education: Artificial Intelligence*, vol. 3, p. 100106, Jan. 2022, doi: 10.1016/J.CAEAI.2022.100106.
- [15] E. Bautista Cañón, J. E. Quirama Salamanca, E. Bautista Cañón, E. Bautista Cañón, J. E. Quirama Salamanca, and E. Bautista Cañón, "Modelo predictivo del progreso en el aprendizaje de los estudiantes de uniminto aplicando técnicas de machine learning," *Conrado*, vol. 17, no. 83, pp. 305–310, 2021, Accessed: Feb. 10, 2025. [Online]. Available: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442021000600305&lng=es&nrm=iso&tlng=es
- [16] M. M. H. Suzan, N. A. Samrin, A. A. Biswas, and M. A. Pramanik, "Students' Adaptability Level Prediction in Online Education using Machine Learning Approaches," in *2021 12th International Conference on Computing Communication and Networking Technologies, ICCCNT 2021*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/ICCCNT51525.2021.9579741.
- [17] J. R. Brinson, "Learning outcome achievement in non-traditional (virtual and remote) versus traditional (hands-on) laboratories: A review of the empirical research," *Comput Educ*, vol. 87, pp. 218–237, Jul. 2015, doi: 10.1016/J.COMPEDU.2015.07.003.
- [18] Y. A. Arteaga Alcívar, E. J. Guaña Moya, L. F. Begnini Domínguez, M. F. Cabrera Córdova, F. Sánchez Cali, and Y. Moya Carrera, "INTEGRACIÓN DE LA TECNOLOGÍA CON LA EDUCACIÓN," *RISTI*, Jul. 2022, Accessed: Feb. 06, 2025. [Online]. Available: <http://190.57.147.202:90/xmlui/handle/123456789/3447>
- [19] A. W. Tony. Bates, Albert. Sangr, and Roc. Filella, "La Gestión de la tecnología en la educación superior: estrategias para transformar la enseñanza y el aprendizaje," *A - Llibres Universitat (IDP-ICE, Octaedro)*, p. 303, 2012, Accessed: Feb. 06, 2025. [Online]. Available: <https://diposit.ub.edu/dspace/handle/2445/144060>
- [20] C. Arteaga, N. Enriquez, and J. L. Chuquimia, "Fides et Ratio - Revista de Difusión cultural y científica de la Universidad La Salle en Bolivia," *Fides et Ratio - Revista de Difusión cultural y científica de la Universidad La Salle en Bolivia*, p. 99, 2015, Accessed: Feb. 06, 2025. [Online]. Available: http://revistasbolivianas.umsa.bo/scielo.php?script=sci_arttext&pid=&lng=es&nrm=iso&tlng=
- [21] F. I. Liliam Jara-Vaca, J. I. Ernesto Chávez-Guevara, I. Catalina Villa-Escudero III, and J. I. Leonardo Novillo-Novillo, "Rol del docente para la educación virtual en tiempos de pandemia: Retos y oportunidades," *Polo del Conocimiento: Revista científico - profesional, ISSN-e 2550-682X, Vol. 6, N.º. 11, 2021, págs. 30-45*, vol. 6, no. 11, pp. 30–45, 2021, doi: 10.23857/pc.v6i11.3248.