



Clasificación multietiqueta basada en ensamble de árboles para estimar competencias docentes inclusivas en la educación superior tecnológica

Ensemble Tree-Based Multi-Label Classification for Estimating Inclusive Teaching Competencies in Technological Higher Education

Gladys Cristina Jácome Morales¹, Alfonso Aníbal Guijarro Rodríguez^{2,3}, Dylan Esteban Sánchez Rak⁴, Jean Carlos Solís Valencia⁵

¹ Carrera de Software, Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil, Ecuador, gladys.jacomem@ug.edu.ec, <https://orcid.org/0000-0003-1922-7988>

² Carrera de software, Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil, Ecuador, alfonso.guijarror@ug.edu.ec, <https://orcid.org/0000-0001-6046-426X>

³ Artificial Intelligence Research Group, University of Guayaquil, Guayas, Ecuador.

⁴ Carrera de software, Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil, Ecuador, dylan.sanchezr@ug.edu.ec, <https://orcid.org/0009-0001-0219-3032>

⁵ Carrera de software, Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil, Ecuador, jean.solisv@ug.edu.ec, <https://orcid.org/0009-0005-8943-1070>

* Correspondence: alfonso.guijarror@ug.edu.ec

Resumen. La atención educativa de estudiantes con necesidades educativas especiales (NEE) en instituciones de educación superior tecnológica depende, en buena medida, de que el cuerpo docente cuente con competencias pedagógicas, inclusivas y tecnológicas que puedan identificarse de forma objetiva y no únicamente mediante apreciaciones subjetivas. Este artículo describe el diseño, el entrenamiento y la evaluación de un prototipo de clasificación multietiqueta que estima, a partir del perfil profesional y formativo de un docente, la presencia de 33 competencias asociadas a cinco categorías de discapacidad: auditiva, visual, física, intelectual y psicosocial. El desarrollo se organizó según las fases de la metodología CRISP-DM sobre un conjunto de 1000 perfiles docentes, cuyas variables categóricas se codificaron mediante One-Hot Encoding y se dividieron en un 80 % para entrenamiento y un 20 % para prueba. Se entrenaron y compararon tres algoritmos —Árbol de Decisión, Random Forest y XGBoost— bajo un esquema MultiOutputClassifier, junto con un modelo de ensamble construido a partir del promedio de las probabilidades de los tres clasificadores. La evaluación combinó precisión, recall y F1-score en sus variantes micro y macro, Hamming Loss, una matriz de confusión agregada, validación cruzada de cinco pliegues y el coeficiente Kappa de Cohen calculado por competencia. Random Forest alcanzó el mejor desempeño global, con un F1-score micro de 0.8054 y un Hamming Loss de 0.2642, mientras que el ensamble evaluado sobre las 33 competencias registró un Kappa promedio de 0.3142, lo que corresponde a un nivel de concordancia aceptable. Los resultados respaldan la viabilidad técnica del enfoque como herramienta de apoyo —y no de reemplazo— para orientar la capacitación docente en escenarios inclusivos, si bien su uso a mayor escala requiere validarse con datos institucionales reales.

Palabras clave: Educación inclusiva, Necesidades educativas especiales, Competencias docentes, Clasificación multietiqueta, Random Forest, Aprendizaje automático.

Abstract. Supporting students with special educational needs (SEN) in technology-oriented higher education institutions largely depends on faculty possessing pedagogical, inclusive, and technological competencies that can be identified objec-

tively rather than through subjective judgment alone. This paper reports the design, training, and evaluation of a multi-label classification prototype that estimates, from a teacher's professional and academic profile, the presence of 33 competencies linked to five disability categories: hearing, visual, physical, intellectual, and psychosocial. Development followed the stages of the CRISP-DM methodology over a dataset of 1,000 teacher profiles, whose categorical variables were encoded through One-Hot Encoding and split into 80% training and 20% test subsets. Three algorithms —Decision Tree, Random Forest, and XGBoost— were trained and compared under a MultiOutputClassifier scheme, together with an ensemble model built from the averaged probabilities of the three classifiers. Evaluation combined precision, recall, and F1-score in their micro and macro variants, Hamming Loss, an aggregated confusion matrix, five-fold cross-validation, and a per-competency Cohen's Kappa coefficient. Random Forest achieved the best overall performance, with a micro F1-score of 0.8054 and a Hamming Loss of 0.2642, while the ensemble evaluated across the 33 competencies obtained an average Kappa of 0.3142, corresponding to an acceptable level of agreement. The results support the technical feasibility of the approach as a decision-support tool —not a replacement— for guiding teacher training in inclusive settings, although broader use requires validation with real institutional data.

Keywords: inclusive education, special educational needs, teaching competencies, multi-label classification, Random Forest, machine learning.

1. Introducción

La diversidad estudiantil presente en la educación superior obliga a las instituciones a garantizar condiciones reales de acceso, permanencia y participación para el alumnado con necesidades educativas especiales (NEE). Diversos organismos internacionales han señalado que, pese a los avances normativos, subsisten brechas en la manera en que las instituciones atienden a esta población [1]. La formación del profesorado constituye un factor determinante, ya que sus conocimientos, actitudes y prácticas pedagógicas inciden directamente en la calidad de la atención brindada a estudiantes con NEE.

En Ecuador, el marco legal vigente reconoce el derecho a la igualdad de oportunidades dentro de la educación superior, pero esta base normativa no garantiza por sí sola que los docentes cuenten con las competencias necesarias para responder a la diversidad del aula. La literatura reciente documenta limitaciones prácticas en la formación docente para la inclusión, particularmente en la región latinoamericana [2], [3], a la vez que reconoce el potencial de la analítica de datos y el aprendizaje automático como recursos capaces de sistematizar información académica y apoyar decisiones institucionales [4].

A partir de esta convergencia entre dos líneas de investigación —la educación inclusiva y la analítica predictiva— surge la posibilidad de construir modelos capaces de estimar, con base en el perfil profesional de un docente, el grado de desarrollo de competencias pedagógicas, inclusivas y tecnológicas vinculadas a la atención de estudiantes con NEE. Este trabajo presenta un prototipo desarrollado con esa finalidad dentro del contexto de la educación superior tecnológica, entendiendo el perfil docente —formación académica, trayectoria profesional, capacitación recibida y prácticas educativas— como variable independiente, y el conjunto de competencias docentes como variable dependiente.

El problema abordado puede formularse mediante la siguiente pregunta de investigación: ¿cómo estimar, mediante un modelo de aprendizaje automático, las competencias docentes requeridas para atender a estudiantes con NEE en la educación superior tecnológica a partir del perfil profesional del profesorado? Para responderla, se plantea como objetivo desarrollar un prototipo de clasificación multietiqueta que compare distintos algoritmos de aprendizaje supervisado y determine cuál ofrece el mejor equilibrio entre capacidad predictiva y estabilidad.

El resto del artículo se organiza de la siguiente manera: la sección 2 resume los antecedentes conceptuales relacionados con la educación inclusiva, las competencias docentes y el aprendizaje automático aplicado a la educación; la sección 3 describe los materiales, el conjunto de datos y el procedimiento metodológico seguido bajo CRISP-DM; la sección 4 presenta los resultados obtenidos por cada algoritmo y por el ensamble; la sección 5 discute los hallazgos frente a la literatura revisada; y la sección 6 expone las conclusiones del estudio.

2. Antecedentes y marco conceptual

La educación inclusiva se entiende como un proceso orientado a identificar y eliminar barreras que limitan el aprendizaje y la participación del estudiantado, reconociendo la diversidad como un componente estructural de la enseñanza y no como una excepción a atender de forma aislada. Las NEE, por su parte, corresponden a situaciones en las que un estudiante requiere apoyos adicionales —humanos, técnicos o pedagógi-



cos— para alcanzar los objetivos de aprendizaje en igualdad de condiciones frente a sus pares [5]. En este estudio se consideraron cinco categorías de NEE (auditiva, visual, física, intelectual y psicosocial), cada una asociada a un conjunto específico de competencias docentes, tales como la comunicación inclusiva, la adaptación de materiales, la accesibilidad física, las adaptaciones curriculares y el manejo socioemocional, entre otras.

Las competencias docentes vinculadas a la inclusión suelen agruparse en tres dimensiones: pedagógicas, relacionadas con la planificación y la evaluación diferenciada; inclusivas, orientadas a la adaptación de estrategias frente a la diversidad; y tecnológicas, referidas al uso de recursos digitales y de asistencia. Estudios previos advierten que la formación docente en inclusión presenta todavía un desarrollo desigual en la región, y que la ausencia de categorías e indicadores claros dificulta valorar objetivamente el nivel de preparación del profesorado [3], [6].

Paralelamente, el aprendizaje automático se ha incorporado de forma creciente en la investigación educativa como herramienta para identificar patrones en grandes volúmenes de información y anticipar resultados que orienten decisiones formativas [7], [8]. En particular, los algoritmos de árboles de decisión y sus variantes de ensamble —Random Forest y XGBoost— destacan por su capacidad de manejar variables mixtas y ofrecer medidas de importancia de variables, lo que resulta útil para interpretar qué características del perfil docente influyen más en la predicción de una competencia [9]. No obstante, la revisión de antecedentes evidencia que estas dos líneas —formación docente inclusiva y modelado predictivo— se han desarrollado mayormente por separado, existiendo pocas propuestas que las articulen dentro de la educación superior tecnológica, lo cual constituye la brecha que este trabajo busca atender.

3. Materiales y métodos

3.1 Diseño y enfoque

El estudio adoptó un diseño cuasi experimental de corte transversal, con un enfoque mixto que combinó la revisión documental para definir las NEE y competencias consideradas con el análisis cuantitativo de datos para el entrenamiento y evaluación del modelo. El desarrollo del prototipo se organizó siguiendo las fases de la metodología CRISP-DM: comprensión del negocio y de los datos, preparación de la información, modelado y evaluación.

3.2 Población, muestra y variables

La población estuvo conformada por 1000 registros de perfiles docentes contenidos en los conjuntos de datos utilizados para la investigación, integrando información sobre formación académica, años de experiencia, horas y cursos de capacitación en educación inclusiva, así como experiencia previa con distintos tipos de discapacidad y uso de recursos y estrategias inclusivas. Al tratarse de información disponible en su totalidad, no se aplicaron técnicas de muestreo probabilístico; se trabajó con la totalidad de los registros disponibles, divididos posteriormente en un 80 % para entrenamiento y un 20 % para prueba.

La variable independiente correspondió al perfil docente, mientras que la variable dependiente estuvo conformada por 33 competencias docentes representadas como variables binarias (presencia o ausencia), distribuidas entre las cinco categorías de NEE señaladas anteriormente. Esta estructura definió un problema de clasificación multietiqueta, en el que cada perfil docente puede asociarse simultáneamente a más de una competencia.

3.3 Preparación de los datos y configuración de los modelos

Las variables categóricas del perfil docente se transformaron mediante One-Hot Encoding, generando una matriz de variables predictoras X que se combinó con las variables numéricas y binarias del conjunto original; la matriz de competencias conformó la variable objetivo Y . Sobre este conjunto se entrenaron tres algoritmos bajo un esquema MultiOutputClassifier, que permite generar predicciones independientes para cada una de las 33 competencias: un Árbol de Decisión con profundidad máxima de diez niveles, un Random Forest de 200 estimadores y un XGBoost de 200 estimadores con profundidad máxima de cuatro niveles y tasa de aprendizaje de 0.1. Adicionalmente, se construyó un modelo de ensamble que combina las probabilidades generadas por los tres algoritmos mediante un promedio ponderado, aplicando después un umbral de decisión de 0.5 para determinar la presencia o ausencia de cada competencia.

El entorno de desarrollo se implementó en Python 3.12 sobre Google Colab, utilizando las bibliotecas Pandas, NumPy y Scikit-Learn para el procesamiento y modelado, XGBoost para el algoritmo homónimo, y



Matplotlib junto con Seaborn para la visualización de resultados y de la matriz de confusión.

3.4 Evaluación del modelo

El desempeño de los modelos se evaluó mediante precisión, recall y F1-score en sus variantes micro y macro, Hamming Loss (proporción de etiquetas mal predichas sobre el total), una matriz de confusión agregada para las 33 competencias, validación cruzada de cinco pliegues (K-Fold) y el coeficiente Kappa de Cohen calculado individualmente para cada competencia, con el propósito de medir el grado de concordancia entre las predicciones del modelo y los valores reales más allá del azar. Complementariamente, se analizó la importancia relativa de cada variable predictora en los tres algoritmos entrenados.

4. Resultados

La tabla 1 resume las métricas de clasificación obtenidas por cada algoritmo sobre el conjunto de prueba. El Árbol de Decisión obtuvo el desempeño más bajo de los tres modelos individuales, con un F1-score micro de 0.7324 y un Hamming Loss de 0.3415. Random Forest alcanzó el mejor resultado global, con un F1-score micro de 0.8054, un recall micro de 0.8542 y el menor Hamming Loss del estudio (0.2642). XGBoost mostró un desempeño intermedio-alto, con un F1-score micro de 0.7827, mientras que el ensamble por promedio de probabilidades (Random Forest + Árbol de Decisión + XGBoost) obtuvo resultados intermedios, sin superar a Random Forest ni a XGBoost por separado.

Tabla 1. Métricas de clasificación por algoritmo (conjunto de prueba)

Modelo	Precisión (micro/macro)	Recall (micro/macro)	F1-score (micro/macro)	Hamming Loss
Árbol de Decisión	0.7346 / 0.7245	0.7301 / 0.7200	0.7324 / 0.7213	0.3415
Random Forest	0.7618 / 0.7528	0.8542 / 0.8428	0.8054 / 0.7947	0.2642
XGBoost	0.7663 / 0.7559	0.7997 / 0.7867	0.7827 / 0.7701	0.2842
Ensamble (RF+DT+XGB)	0.7535 / 0.7417	0.7881 / 0.7745	0.7704 / 0.7570	0.3006

Nota: elaboración propia a partir de los datos del prototipo desarrollado.

La matriz de confusión agregada, calculada sobre las 33 competencias evaluadas con el modelo de ensamble, registró 3329 verdaderos positivos, 1287 verdaderos negativos, 1089 falsos positivos y 895 falsos negativos (tabla 2). La mayor concentración de casos se ubicó sobre la diagonal principal, lo que confirma una proporción considerable de predicciones correctas; asimismo, el menor número de falsos negativos frente a los falsos positivos indica que el modelo tiende a identificar con mayor facilidad las competencias presentes que a descartar las ausentes.

Tabla 2. Matriz de confusión agregada del modelo de ensamble (33 competencias)

	Predicho: Presente	Predicho: Ausente	Total real
Real: Presente	3329 (VP)	895 (FN)	4224
Real: Ausente	1089 (FP)	1287 (VN)	2376
Total predicho	4418	2182	6600

Nota: VP = verdadero positivo, VN = verdadero negativo, FP = falso positivo, FN = falso negativo. A partir de estos conteos: exactitud = 0.6994, precisión = 0.7536, recall = 0.7881 y F1-score = 0.7705 (valores micro), y Hamming Loss = 0.3006 — cifras que coinciden con las reportadas para el ensamble en la tabla 1, lo que confirma la consistencia interna de los resultados.

La validación cruzada de cinco pliegues confirmó la estabilidad de los resultados anteriores (tabla 3). Random Forest mantuvo el mejor desempeño, con un F1-micro promedio de 0.8062 y una desviación estándar de apenas 0.0104 entre pliegues, seguido por XGBoost (F1-micro de 0.7845, desviación de 0.0109) y el Árbol de Decisión (F1-micro de 0.7301, desviación de 0.0121). La baja dispersión observada en los tres modelos sugiere que el rendimiento obtenido no depende de una partición específica de los datos, lo que respalda la capacidad de generalización del prototipo.

Tabla 3. Validación cruzada de cinco pliegues por algoritmo

Modelo	F1-micro promedio	Desv. estándar	Hamming Loss
Árbol de Decisión	0.7301	0.0121	0.3413
Random Forest	0.8062	0.0104	0.2606
XGBoost	0.7845	0.0109	0.2819



Nota: elaboración propia a partir de los datos del prototipo desarrollado.

El coeficiente Kappa de Cohen, calculado para cada una de las 33 competencias sobre las predicciones del ensamble, arrojó un promedio de 0.3142, correspondiente a un nivel de concordancia aceptable. La tabla 4 resume las competencias con mayor y menor grado de acuerdo. Las competencias con mayor acuerdo fueron trabajo con la familia (Kappa = 0.5051), trabajo con profesionales de apoyo (0.4932), uso de tecnologías de asistencia (0.4629) y promoción de la participación (0.4618); en contraste, las competencias de descripción verbal de contenidos (0.1897), eliminación de barreras físicas (0.1867) y ambiente inclusivo (0.0924) registraron los niveles más bajos, lo que sugiere mayor dificultad del modelo para diferenciarlas a partir del perfil docente disponible.

Tabla 4. Coeficiente Kappa de Cohen por competencia — valores extremos (modelo de ensamble)

Competencia	Kappa de Cohen	Nivel de concordancia*
Trabajo con la familia	0.5051	Moderado
Trabajo con profesionales de apoyo	0.4932	Moderado
Uso de tecnologías de asistencia	0.4629	Moderado
Promoción de la participación	0.4618	Moderado
Descripción verbal de contenidos	0.1897	Leve
Eliminación de barreras físicas	0.1867	Leve
Ambiente inclusivo	0.0924	Insignificante-leve
Promedio (33 competencias)	0.3142	Aceptable / razonable

* Interpretación según la escala convencional de Landis y Koch para el coeficiente Kappa. Nota: elaboración propia a partir de los datos del prototipo desarrollado.

En cuanto a la importancia de variables, los tres algoritmos coincidieron en otorgar mayor peso a factores relacionados con la experiencia y la formación en educación inclusiva (tabla 5). En el Árbol de Decisión, la variable de mayor influencia fue el trabajo previo en educación inclusiva (0.1503), seguida de las horas de capacitación (0.1226) y los años de experiencia (0.0930). En Random Forest, la importancia se distribuyó de forma más equilibrada, encabezada por las horas de capacitación (0.1229), los años de experiencia (0.0825) y el número de cursos en educación inclusiva (0.0775). XGBoost, en cambio, concentró gran parte de su capacidad predictiva en una sola variable —el trabajo previo en educación inclusiva—, con una importancia de 0.2842, muy por encima del resto de las características consideradas.

Tabla 5. Importancia relativa de las tres variables más influyentes, por algoritmo

Algoritmo	1.ª variable	2.ª variable	3.ª variable
Árbol de Decisión	Trabajo previo en ed. inclusiva (0.1503)	Horas de capacitación (0.1226)	Años de experiencia (0.0930)
Random Forest	Horas de capacitación (0.1229)	Años de experiencia (0.0825)	N.º cursos en ed. inclusiva (0.0775)
XGBoost	Trabajo previo en ed. inclusiva (0.2842)	—	—

Nota: valores de importancia relativa (0–1) según cada algoritmo. Elaboración propia.

5. Discusión

Los resultados obtenidos coinciden con lo señalado por la literatura respecto a la capacidad de los algoritmos de ensamble basados en árboles para modelar relaciones complejas entre variables heterogéneas propias de contextos educativos [9]. En particular, el mejor desempeño de Random Forest frente a XGBoost y al Árbol de Decisión puede explicarse por su mecanismo de promediado entre múltiples árboles, que reduce la varianza del modelo y favorece una mayor sensibilidad (recall) sin sacrificar de forma importante la precisión, comportamiento que resulta favorable en un problema donde omitir una competencia presente (falso negativo) puede tener mayores implicaciones prácticas que sobreestimarla.

El hecho de que las variables más influyentes se relacionen con la experiencia y la capacitación en educación inclusiva —y no exclusivamente con la formación académica formal— es consistente con investigaciones que señalan que la práctica situada y la formación continua inciden de manera decisiva en el desarrollo de competencias inclusivas del profesorado [3]. Este hallazgo sugiere que las instituciones podrían obte-



ner mayor beneficio orientando sus políticas de capacitación hacia la experiencia práctica acumulada y la formación continua, en lugar de basarse únicamente en indicadores de titulación.

El nivel de concordancia moderado obtenido mediante el coeficiente Kappa de Cohen (0.3142) indica que, si bien el modelo supera claramente el desempeño esperado por azar, existe margen de mejora, particularmente en competencias con baja representación en los datos, como la eliminación de barreras físicas o la construcción de un ambiente inclusivo. Esta limitación es coherente con lo observado en estudios sobre analítica de aprendizaje, donde el desbalance de clases suele afectar de manera diferenciada a las categorías menos frecuentes [10]. Por tanto, los resultados deben interpretarse como una aproximación inicial, susceptible de mejorar mediante conjuntos de datos más amplios y balanceados, y no como una medición definitiva del desempeño docente.

6. Conclusiones

El prototipo desarrollado demuestra que es técnicamente factible estimar, mediante algoritmos de clasificación multietiqueta, un conjunto amplio de competencias docentes vinculadas a la atención de estudiantes con NEE a partir del perfil profesional del profesorado. Entre los tres algoritmos evaluados, Random Forest ofreció el mejor equilibrio entre capacidad predictiva, estabilidad durante la validación cruzada y control de errores, medido a través de un F1-score micro de 0.8054 y el menor Hamming Loss del estudio.

El análisis de importancia de variables evidenció que la experiencia práctica y la capacitación específica en educación inclusiva pesan más que la sola formación académica formal en la estimación de competencias, lo que aporta un criterio orientador para el diseño de programas de formación docente. Asimismo, el coeficiente Kappa de Cohen confirmó una concordancia aceptable entre las predicciones y los valores reales, aunque desigual entre competencias, lo que señala la necesidad de ampliar y balancear los datos disponibles antes de considerar una implementación institucional.

En conjunto, los hallazgos respaldan el uso de modelos de aprendizaje automático como herramienta de apoyo a la toma de decisiones en procesos de capacitación docente orientados a la inclusión, sin que ello sustituya el juicio profesional de los equipos pedagógicos. Como líneas futuras se recomienda validar el prototipo con datos institucionales reales de distintas universidades tecnológicas, ampliar el balance de clases para las competencias menos representadas y explorar técnicas adicionales de ajuste de hiperparámetros que permitan mejorar la concordancia obtenida en las competencias con menor Kappa.

Referencias

- [1] UNESCO, "Global Education Monitoring Report 2023: Technology in education: A tool on whose terms?" GEM Report UNESCO, Paris, France, 2023. <https://doi.org/10.54676/UZQV8501>
- [2] C. Herrera-Seda and E. Walton, "Teacher education for inclusive education: a scoping review of Global South scholarship," *Journal of Education for Teaching*, vol. 51, no. 4, pp. 651–665, 2025. <https://doi.org/10.1080/02607476.2025.2520792>
- [3] T. Laspina-Olmedo and D. Montero, "Competencia inclusiva en la práctica docente: análisis bibliográfico y propuesta de categorización," *Alteridad*, vol. 18, no. 2, pp. 177–186, 2023. <https://doi.org/10.17163/alt.v18n2.2023.02>
- [4] E. J. Medina-Hernández, J. L. Muñiz, D. S. Guzmán-Aguilar, and A. Holguín-Higueta, "Recursos y estrategias para la enseñanza de la estadística y la analítica de datos en la educación superior," *Formación Universitaria*, vol. 15, no. 3, pp. 61–68, 2022. <https://doi.org/10.4067/S0718-50062022000300061>
- [5] UNIR, "¿Qué son las necesidades educativas especiales (NEE)?," UNIR Ecuador, 2022. <https://ecuador.unir.net/actualidad-unir/necesidades-educativas-especiales/>
- [6] E. Garcés Suárez, O. Alcívar Fajardo, and E. Garcés Suárez, "La educación inclusiva en la universidad: reclamos y propuestas," *Revista Universidad y Sociedad*, vol. 14, no. 2, pp. 336–343, 2022.
- [7] F. Ouyang, M. Wu, L. Zheng, L. Zhang, and P. Jiao, "Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course," *International Journal of Educational Technology in Higher Education*, vol. 20, no. 1, 2023. <https://doi.org/10.1186/s41239-022-00372-4>
- [8] W. Forero-Corba and F. Negre Bennasar, "Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: una revisión sistemática," *RIED-Revista Iberoamericana de Educación a Distancia*, vol. 27, no. 1, pp. 209–253, 2024. <https://doi.org/10.5944/ried.27.1.37491>
- [9] A. Mohammed and R. Kora, "A comprehensive review on ensemble deep learning: Opportunities and challeng-



- es," *Journal of King Saud University – Computer and Information Sciences*, vol. 35, no. 2, pp. 757–774, 2023. <https://doi.org/10.1016/j.jksuci.2023.01.014>
- [10] J. Mella-Norambuena, M. G. Badilla-Quintana, and Y. López Angulo, "Modelos predictivos basados en uso de analíticas de aprendizaje en educación superior: una revisión sistemática," *Texto Livre*, vol. 15, e36310, 2022. <https://doi.org/10.35699/1983-3652.2022.36310>
- [11] M. V. Pico Gordón, "Optimización de Programas Educativos Inclusivos mediante Modelación Estadística y Minería de Datos," *Innovación Integral*, vol. 1, no. 4, pp. 1–16, 2024. <https://doi.org/10.70577/chdc6n20> [referencia no citada en el texto — revisar antes de enviar]

Recibido el [fecha]. Aceptado el [fecha]

