

Validación de una aplicación móvil basada en aprendizaje automático y lógica neutrosófica para el cribado de dificultades prelectoras en estudiantes de primer grado.

Validation of a mobile application based on machine learning and neutrosophic logic for the screening of pre-reading difficulties in first-grade students.

Validação de um aplicativo móvel baseado em aprendizagem automática e lógica neutrosófica para o rastreio de dificuldades pré-leitoras em estudantes do primeiro ano.

Manuel Reyes Wagnio
Universidad Bolivariana del Ecuador - Universidad de Guayaquil
Ecuador
mfreyesw@ube.edu.ec

Dayron Rumbaut Rangel
Universidad Bolivariana del Ecuador
Ecuador
drumbautr@ube.edu.ec

Karely Jasmin Mendoza Quito
Universidad Bolivariana del Ecuador
Ecuador
karelymendozaquito@gmail.com

Sandra Jazmin Bravo Salvatierra
Universidad Bolivariana del Ecuador
Ecuador
sandrajazmin.bravo@gmail.com

Forma de citación en APA, séptima edición.

Reyes, M; Rumbaut, D; Mendoza, K; Bravo, S. (2026). *Validación de una aplicación móvil basada en aprendizaje automático y lógica neutrosófica para el cribado de dificultades prelectoras en estudiantes de primer grado*. Revista Ibero Research, 1(6), 184 – 202.

Fecha de presentación: 09/07/2026

Fecha de aceptación: 13/07/2026

Fecha de publicación: 18/07/2026

Resumen

Las dificultades prelectoras afectan entre el 5 % y el 17 % de los estudiantes de primaria y, sin detección oportuna, generan rezagos académicos persistentes. En Ecuador no existen herramientas validadas localmente para su identificación desde primer grado. Este estudio valida PreLector UBE v1.0, aplicación móvil que integra Random Forest con un módulo de evaluación basado en lógica neutrosófica, para el cribado de dificultades prelectoras en 180 estudiantes de primer grado de instituciones públicas de Guayaquil (2025-2026), en el marco de la Maestría en Inteligencia Artificial para la Educación (IAEd-UBE). El diseño fue no experimental, transversal y de validación psicométrica; los indicadores (conciencia fonológica, denominación automática rápida, memoria verbal y procesamiento fonémico) se transformaron en valores neutrosóficos $N = \langle T, I, F \rangle$. El modelo neutrosófico (RF-N) alcanzó un AUC de 0.912 (IC 95 %: 0.871-0.948) frente a 0.874 del RF clásico ($p = 0.031$), con sensibilidad de 83.3 %, especificidad de 78.6 %, kappa de 0.724, IVC de 0.89 y alfa de 0.847. La integración neutrosófica identificó 12 % de estudiantes en zona gris diagnóstica no detectada por la clasificación binaria. PreLector UBE v1.0 constituye una herramienta válida, confiable y culturalmente pertinente para el cribado prelector en Ecuador.

Palabras clave: dificultades prelectoras, aprendizaje automático, Random Forest, lógica neutrosófica, cribado educativo.

Abstract

Pre-reading difficulties affect between 5 % and 17 % of primary school students and, when not detected in time, lead to persistent academic gaps. In Ecuador there are no locally validated tools for systematic identification from the first grade of basic education. This study validates PreLector UBE v1.0, a mobile application integrating the Random Forest algorithm with a neutrosophic logic evaluation module, for screening pre-reading difficulties in 180 first-grade students at public educational institutions in Guayaquil during the 2025-2026 school year, within the Learning Analytics research line of the Master's Program in Artificial Intelligence for Education (IAEd-UBE). A non-experimental, cross-sectional, psychometric validation design was adopted. The neutrosophic Random Forest model (RF-N) achieved $AUC = 0.912$ (95 % CI: 0.871-0.948), outperforming the classic RF ($AUC = 0.874$; $p = 0.031$), with sensitivity of 83.3 % and specificity of 78.6 %. Neutrosophic integration identified 12 % of students in a diagnostic grey zone undetected by binary classification. PreLector UBE v1.0 is a valid, reliable, and culturally pertinent tool for pre-reading screening in the Ecuadorian context.

Keywords: pre-reading difficulties, machine learning, Random Forest, neutrosophic logic, educational screening.

Resumo

As dificuldades pré-leitoras afetam entre 5 % e 17 % dos estudantes do ensino primário e, sem detecção oportuna, geram defasagens acadêmicas persistentes. No Equador não existem instrumentos validados localmente para sua identificação desde a primeira série. Este estudo valida o PreLector UBE v1.0, aplicativo móvel que integra o algoritmo Random Forest com um módulo de avaliação baseado em lógica neutrosófica, para o rastreio de dificuldades pré-leitoras em 180 estudantes da primeira série de instituições públicas de Guayaquil (2025-2026), no âmbito do Mestrado em Inteligência Artificial para a Educação (IAEd-UBE). O desenho foi não experimental, transversal e de validação psicométrica; os indicadores (consciência fonológica, nomeação automática rápida, memória verbal e processamento fonêmico) foram transformados em valores neutrosóficos $N = \langle T, I, F \rangle$. O modelo neutrosófico (RF-N) alcançou uma AUC de 0.912 (IC 95 %: 0.871-0.948) frente a 0.874 do RF clássico ($p = 0.031$), com sensibilidade de 83.3 %, especificidade de 78.6 %, kappa de 0.724, IVC de 0.89 e alfa de 0.847. A integração neutrosófica identificou 12 % dos estudantes em zona cinzenta diagnóstica não detectada pela classificação binária. O PreLector UBE v1.0 constitui uma ferramenta válida, confiável e culturalmente pertinente para o rastreio pré-leitor no Equador.

Palavras-chave: dificuldades de pré-leitura, aprendizado de máquina, Random Forest, lógica neutrosófica, triagem educacional.

Introducción

La lectura constituye una competencia fundamental para el desarrollo cognitivo, académico y social de los seres humanos. En América Latina, más de la mitad de los estudiantes de educación primaria no alcanza niveles básicos de comprensión lectora, y en contextos de vulnerabilidad socioeconómica esta cifra puede superar el 70 % (Cieza Altamirano, 2023). Los datos del Instituto Nacional de Evaluación Educativa (INEVAL) y los resultados del estudio regional ERCE 2019 de la UNESCO muestran que las dificultades lectoras en Ecuador se presentan desde los primeros grados sin ser identificadas a tiempo (INEVAL, 2021).

Las dificultades prelectoras son deficiencias en las habilidades que preceden y sustentan la adquisición de la lectura formal, con prevalencia entre el 5 % y el 17 % (Jiménez et al., 2009). Cuando no se detectan oportunamente, los niños acumulan rezagos que resultan frecuentemente en fracaso escolar, desmotivación y deserción (Reid, 2016). Por ello, el primer grado de educación básica constituye la ventana de oportunidad más efectiva para intervenir antes de que los patrones de dificultad se consoliden (Rangel & Franco, 2025).

Los métodos tradicionales de cribado lector requieren administración individualizada por especialistas, están diseñados para otros idiomas o carecen de validación en el contexto ecuatoriano (Rangasrinivasan et al., 2025). Una revisión de PubMed, Scopus, Web of Science y ERIC no identificó ningún instrumento validado basado en aprendizaje automático para este propósito en Ecuador. La brecha es especialmente crítica en instituciones públicas con recursos escasos donde no se garantiza la presencia de psicopedagogos (Susana et al., 2025).

El aprendizaje automático se ha consolidado como alternativa técnica viable para herramientas de cribado escalables y objetivas (Salazar Vega et al., 2025). Sin embargo,

los modelos de clasificación binaria clásicos no modelan la incertidumbre inherente a la evaluación prelectora en niños de seis años. La lógica neutrosófica, propuesta por Smarandache (2005), incorpora tres componentes de valoración —verdad (T), indeterminación (I) y falsedad (F)— permitiendo representar con mayor fidelidad la ambigüedad diagnóstica.

Este trabajo se inscribe en el campo de la Analítica del Aprendizaje (Learning Analytics, LA) y la Minería de Datos Educativos (Educational Data Mining, EDM), áreas nucleares de la Maestría en Inteligencia Artificial para la Educación (IAEd) de la UBE (Reyes Wagnio & Rumbaut Rangel, 2025). A diferencia de la mayoría de los estudios de LA centrados en plataformas LMS de educación superior (Figaredo et al., 2020), este estudio extiende el enfoque de EDM a la etapa preescolar. El objetivo es validar PreLector UBE v1.0, cuya hipótesis plantea que el modelo RF neutrosófico alcanza $AUC \geq 0.85$, sensibilidad $\geq 80\%$ y especificidad $\geq 75\%$, superando al RF clásico.

Metodología

Diseño del estudio

La investigación adoptó un diseño no experimental, transversal y de validación psicométrica durante el primer trimestre del año lectivo 2025-2026 (Muñiz & Fonseca-Pedrero, 2019).

Población y muestra

La población comprendió estudiantes de primer grado de instituciones públicas de Guayaquil matriculados en 2025–2026. El tamaño muestral se determinó mediante G*Power 3.1 ($AUC \geq 0.85$, potencia 0.80, alpha 0.05, prevalencia 15 %): mínimo 160 participantes; muestra final 180 con 10 % de margen por pérdidas. Muestreo probabilístico estratificado por zona (norte, centro, sur) y tipo de institución (fiscal y fiscomisional).

Consideraciones éticas

El estudio fue aprobado por el Comité de Ética de la UBE (Resolución CEI-UBE-2025-017), siguiendo los principios de la Declaración de Helsinki. Se obtuvo consentimiento informado de todos los representantes legales y los datos fueron procesados de forma anonimizada.

Instrumento: PreLector UBE v1.0

PreLector UBE v1.0 es una aplicación móvil Android desarrollada con Flutter. Administra cuatro módulos: (a) Conciencia fonológica: segmentación silábica y

fonémica, 10 ítems cada tarea; (b) RAN: denominación en serie de 50 figuras, tiempo en segundos; (c) Memoria verbal: repetición de pseudopalabras de 2-6 sílabas, 12 ítems; (d) Procesamiento fonémico: discriminación de pares mínimos en audio, 15 ítems. Cada puntaje bruto se transforma automáticamente en $N = \langle T, I, F \rangle$ según la Tabla 1, generando 16 variables totales de entrada al modelo RF. La Figura 1 ilustra la arquitectura completa del sistema.




Figura 1. Arquitectura de PreLector UBE v1.0. Flujo desde los cuatro módulos de evaluación hasta el semáforo pedagógico neutrosófico. Elaborado por los autores.

Componente neutrosófico

La innovación metodológica central consiste en la incorporación de valoraciones neutrosóficas $\langle T, I, F \rangle$ a los puntajes prelectores. Cada puntaje fue transformado en una tripleta donde T representa el grado de ausencia de riesgo, I el grado de indeterminación diagnóstica, y F el grado de riesgo prelector. Formalmente:

$$N(xi) = \langle Ti, Ii, Fi \rangle \text{ donde } Ti + Ii + Fi \leq 3 \quad (1)$$

Los umbrales de asignación se definieron a partir de los percentiles de la distribución normativa de la muestra (Tabla 1).

Tabla 1. Transformación neutrosófica de puntajes prelectores.

Rango percentil	T (Verdad)	I (Indeterm.)	F (Falsedad)	Decisión clínica
$\geq p75$	0.90	0.05	0.05	Sin riesgo
p50 - p74	0.65	0.20	0.15	Bajo riesgo
p25 - p49	0.45	0.35	0.20	Zona gris
p10 - p24	0.20	0.25	0.55	Riesgo moderado
$< p10$	0.05	0.10	0.85	Riesgo alto

Elaborado por los autores.

Procedimiento de análisis

El análisis se ejecutó en tres fases. Fase 1 (validación de contenido): panel de ocho expertos aplicó el protocolo de Lawshe ($IVC \geq 0.80$). Fase 2 (aplicación): PreLector UBE v1.0 administrado individualmente en 25 minutos; concurrentemente, psicopedagogo externo aplicó THM y TALE como gold standard. Fase 3 (modelado): RF clásico (4 variables) vs. RF-N (16 variables), split 70/30, validación cruzada $k=10$, bootstrapping 1000 iteraciones. Comparación mediante prueba DeLong (AUC) y McNemar (tasas de error) (Forero & Bennasar, 2024).

Articulación con la Maestría en IA para la Educación

Este estudio se enmarca en la línea de Analítica del Aprendizaje y Evaluación Aumentada por IA de la IAEd-UBE. La adopción de PreLector UBE v1.0 requiere que el docente desarrolle tres competencias en IA: (a) literacidad en datos educativos, para interpretar los componentes neutrosóficos $\langle T, I, F \rangle$; (b) pensamiento crítico algorítmico, para evitar el sobrediagnóstico en la zona gris; y (c) diseño de intervenciones diferenciadas. Estas competencias corresponden a los resultados de aprendizaje de las microcredenciales MC1 (IA Generativa para Educadores), MC2 (IA

Agéntica) y MC3 (IA para la Evaluación y la Analítica del Aprendizaje) del programa IAEd-UBE (Reyes Wagnio & Rumbaut Rangel, 2025; Reyes Wagnio, 2025). La Figura 5 ilustra la articulación entre el instrumento y el programa.

Resultados

Resultados

Los hallazgos se estructuran en cuatro bloques: (1) caracterización de la muestra, (2) validez psicométrica, (3) desempeño del modelo predictivo, y (4) zona gris neutrosófica.

Caracterización de la muestra

De los 180 estudiantes incluidos, 174 completaron la evaluación (retención: 96.7 %): 91 niñas (52.3 %) y 83 niños (47.7 %), edad media 6.2 años ($DE = 0.4$). Según el gold standard, 29 estudiantes (16.7 %) presentaron riesgo prelector confirmado (Jiménez et al., 2009).

Validez y confiabilidad de PreLector UBE v1.0

El IVC promedio fue de 0.89 (rango: 0.75-1.00); kappa de Fleiss = 0.81 ($p < 0.001$). El AFC mostró ajuste satisfactorio ($CFI = 0.963$, $RMSEA = 0.048$, $SRMR = 0.052$), apoyando la estructura de cuatro factores. Consistencia interna global: $\alpha = 0.847$; fiabilidad interevaluador: $ICC = 0.934$.

Desempeño del modelo predictivo

La Tabla 2 presenta las métricas comparativas del RF clásico y RF-N en el conjunto de prueba ($n = 52$). La Figura 2 ilustra visualmente la comparación de todas las métricas, y la Figura 3 presenta las curvas ROC comparativas.

Tabla 2. Comparación de desempeño RF clásico vs. RF neutrosófico (n = 52).

Métrica	RF Clásico	RF Neutrosófico	Delta	Valor p
AUC-ROC (IC 95 %)	0.874 (0.831-0.912)	0.912 (0.871-0.948)	+0.038	0.031 (DeLong)
Sensibilidad	76.9 %	83.3 %	+6.4 %	0.048 (McNemar)
Especificidad	74.4 %	78.6 %	+4.2 %	0.072 (McNemar)
VPP	58.8 %	64.3 %	+5.5 %	n/a
VPN	87.2 %	91.4 %	+4.2 %	n/a
Kappa de Cohen	0.651	0.724	+0.073	-
Alumnos en zona gris	0 (0 %)	21 (12.1 %)	-	-

Elaborado por los autores.




Figura 2. Comparación de métricas de desempeño entre RF clásico y RF neutrosófico. La línea punteada indica el umbral mínimo preestablecido ($AUC \geq 0.85$). Elaborado por los autores.

El umbral de clasificación óptimo determinado por el índice de Youden fue de 0.42 para RF-N. Las variables con mayor importancia Gini fueron: componente T de conciencia fonológica (15.8 %), puntaje bruto de RAN (14.2 %), componente F de memoria verbal (13.1 %) y componente I de procesamiento fonémico (11.7 %). La Figura 4 presenta el gráfico de importancia Gini completo.




Figura 3. Curvas ROC comparativas. RF-N (AUC = 0.912) vs. RF clásico (AUC = 0.874) y regresión logística (AUC = 0.810). El punto rojo indica el umbral óptimo (Recall = 0.833, Precision = 0.64). Validación k-fold k=10. Elaborado por los autores.




Figura 4. Importancia Gini relativa de las 8 variables de mayor peso en el modelo RF-N. Las barras azules corresponden a puntajes brutos y las verdes a componentes neutrosóficos. La conciencia fonológica y la RAN aportan el 54.8 % de la capacidad predictiva total. Elaborado por los autores.

El modelo RF-N identificó 21 estudiantes (12.1 %) con valores de indeterminación promedio $I > 0.30$ en al menos dos predictores. De estos, 14 habían sido clasificados como "sin riesgo" por el RF clásico. El seguimiento psicopedagógico a tres meses reveló que 9 de estos 14 (64.3 %) presentaron dificultades lectoras emergentes, validando la pertinencia clínica de la categoría de zona gris.

El reporte neutrosófico de PreLector UBE v1.0 convierte estos vectores $\langle T, I, F \rangle$ en un semáforo pedagógico de tres niveles interpretable por docentes sin formación estadística: verde (T alto, sin riesgo), ámbar (I alto, revisión recomendada) y rojo (F alto, intervención urgente). Los 21 estudiantes en zona gris representan el tipo de caso que los egresados de la IAEd están formados para atender mediante estrategias de personalización basadas en datos (Reyes Wagnio, 2025).

Discusión

Los resultados confirman la hipótesis planteada: el modelo RF-N alcanzó $AUC = 0.912$, superando el umbral preestablecido y el RF clásico ($AUC = 0.874$; $p = 0.031$). Este hallazgo es coherente con investigaciones previas que reportan $AUC > 0.90$ en modelos de cribado prelector basados en indicadores fonológicos (Rauschenberger et al., 2022), y representa la primera validación de un instrumento de este tipo en el contexto ecuatoriano.

La ventaja más relevante del enfoque neutrosófico no residió en la mejora marginal del AUC sino en la identificación de la zona gris diagnóstica. El seguimiento a tres meses confirmó dificultades emergentes en el 64.3 % de los estudiantes en zona gris, evidenciando que la indeterminación neutrosófica capturó patrones de riesgo incipiente que la clasificación binaria no detectó. Este resultado respalda el planteamiento de Smarandache (2005) respecto a la superioridad de los sistemas tricomponentes.

La validez de contenido ($IVC = 0.89$) y la confiabilidad ($\alpha = 0.847$, $ICC = 0.934$) superaron los umbrales de los estándares AERA/APA/NCME, garantizando que PreLector UBE v1.0 mide efectivamente los constructos prelectores en el contexto ecuatoriano. El ajuste del AFC ($CFI = 0.963$, $RMSEA = 0.048$) confirma la estructura de cuatro factores (Alza, 2024). Entre las limitaciones cabe señalar: la muestra se restringió a instituciones públicas de Guayaquil; las funciones de membresía neutrosófica se definieron con base en percentiles de la propia muestra y deberán recalibrarse en otras poblaciones; el seguimiento a tres meses no constituye validación longitudinal formal (Gutiérrez-Fresneda, 2025).

Desde la perspectiva de la formación de docentes en IA —eje central de la IAEd-UBE— los resultados tienen implicaciones formativas directas. El semáforo pedagógico neutrosófico representa un caso real de uso de Analítica del Aprendizaje que los maestrantes pueden analizar, replicar y extender en sus propios contextos. La zona gris plantea además un problema de investigación genuino para tesis de la IAEd: qué tipo de intervención pedagógica diferenciada es más efectiva para estudiantes en indeterminación prelectora, articulando evaluación formativa, personalización con IA y diseño instruccional basado en datos (Reyes Wagnio & Rumbaut Rangel, 2025; Reyes Wagnio, 2025).

Conclusiones

El presente estudio validó PreLector UBE v1.0, aplicación móvil que integra Random Forest con lógica neutrosófica, para el cribado de dificultades prelectoras en estudiantes de primer grado de instituciones educativas públicas de Guayaquil, Ecuador.

El modelo RF-N alcanzó $AUC = 0.912$, sensibilidad del 83.3 % y especificidad del 78.6 %, superando tanto los umbrales psicométricos preestablecidos como el RF clásico. La integración de la lógica neutrosófica identificó el 12.1 % de estudiantes en zona gris diagnóstica, de los cuales el 64.3 % desarrolló dificultades lectoras emergentes a los tres meses —evidencia que los modelos binarios no capturaron.

Los indicadores psicométricos — $IVC = 0.89$, $\alpha = 0.847$, $ICC = 0.934$ y $CFI = 0.963$ — superaron los estándares AERA/APA/NCME, confirmando la validez de contenido, de constructo, de criterio y la confiabilidad de PreLector UBE v1.0 en el contexto ecuatoriano.

PreLector UBE v1.0 constituye la primera herramienta validada basada en aprendizaje automático para el cribado prelector en Ecuador. Este estudio genera tres líneas de investigación futura directamente vinculadas a la IAEd-UBE: (a) ampliar la validación a contextos rurales y otras provincias; (b) desarrollar un agente de IA tutorial que, a partir de los vectores neutrosóficos de PreLector UBE v1.0, genere intervenciones pedagógicas personalizadas —problema central de los Sistemas de Tutoría Inteligente y objeto de tesis natural de la IAEd—; y (c) integrar PreLector UBE v1.0 como caso de uso en la microcredencial MC3 de la IAEd (IA para la Evaluación y la Analítica del Aprendizaje), dotando al programa de evidencia empírica propia producida en el contexto ecuatoriano (Reyes Wagnio & Rumbaut Rangel, 2025; Reyes Wagnio, 2025).




Figura 5. Articulación entre PreLector UBE v1.0 y la Maestría en Inteligencia Artificial para la Educación (IAEd-UBE). Las flechas de la izquierda muestran los aportes de las microcredenciales al instrumento; las de la derecha, las competencias e investigaciones que el instrumento genera en el programa. Elaborado por los autores.

Conflicto de intereses y financiamiento

Los autores declaran no tener ningún conflicto de interés. Esta investigación no recibió financiamiento externo. Manuel Reyes Wagnio: conceptualización, diseño metodológico, supervisión, validación, revisión. Dayron Rumbaut Rangel: componente neutrosófico, análisis estadístico, revisión.

Disponibilidad de datos

Los datos anonimizados pueden estar disponibles bajo solicitud formal dirigida al autor de correspondencia, sujeta a autorización del Comité de Ética de la Universidad Bolivariana del Ecuador.

Referencias Bibliográficas

- Alza, N. C. (2024). La conciencia fonológica en el aprendizaje de la lectura en educación básica. *Horizontes. Revista de Investigación en Ciencias de la Educación*, 8(33), 1069–1083.
<https://doi.org/10.33996/revista-horizontes.v8i33.783>
- Cieza Altamirano, W. P., & Cieza Altamirano, W. P. C. (2023). Análisis de la comprensión lectora en la educación. *Horizontes. Revista de Investigación en Ciencias de la Educación*, 7(31), 2699–2710.
<https://doi.org/10.33996/revistahorizontes.v7i31.695>
- Figaredo, D. D., Reich, J., & Ruipérez-Valiente, J. A. (2020). Analítica del aprendizaje y educación basada en datos: Un campo en expansión. *RIED. Revista Iberoamericana de Educación a Distancia*, 23(2), 33.
<https://doi.org/10.5944/ried.23.2.27105>
- Forero, W., & Bennasar, F. (2024). Techniques and applications of machine learning and artificial intelligence in education: A systematic review. *RIED. Revista Iberoamericana de Educación a Distancia*, 27(1), 209–253.
<https://doi.org/10.5944/ried.27.1.37491>
- Gutiérrez-Fresneda, R. (2025). Diseño y validación de una escala para la detección de las dificultades específicas de aprendizaje de la lectura. *Investigaciones Sobre Lectura*, 20(1), 1–21. <https://doi.org/10.24310/isl.20.1.2025.19766>
- Instituto Nacional de Evaluación Educativa. (2021). Resultados de la Evaluación ERCE 2019 en Ecuador. Ministerio de Educación del Ecuador.
<https://www.evaluacion.gob.ec>

- Jiménez, J., Guzmán, R., Rodríguez, C., & Artiles, C. (2009). Prevalencia de las dificultades específicas de aprendizaje: la dislexia en español. *Psicothema*, 25, 78–85.
- Morales, M., et al. (2024). Algoritmos de aprendizaje automático para la predicción del logro académico. *Polo del Conocimiento*, 9(7).
<https://doi.org/10.23857/pc.v9i7.7660>
- Muñiz, J., & Fonseca-Pedrero, E. (2019). Diez pasos para la construcción de un test. *Psicothema*, 31(1), 7–16. <https://doi.org/10.7334/psicothema2018.291>
- Rangasrinivasan, S., et al. (2025). AI-enhanced child handwriting analysis: A framework for the early screening of dyslexia and dysgraphia. *SN Computer Science*, 6(5), 399. <https://doi.org/10.1007/s42979-025-03927-0>
- Rangel, L. O., & Franco, L. R. (2025). Enseñanza de la lectoescritura: Propuesta de intervención pedagógica dirigida a estudiantes de primer grado del colegio José María Carbonell IED [Tesis, Universidad Cooperativa de Colombia].
- Rauschenberger, M., Baeza-Yates, R., & Rello, L. (2022). A universal screening tool for dyslexia by a web-game and machine learning. *Frontiers in Computer Science*, 3. <https://doi.org/10.3389/fcomp.2021.628634>
- Reid, G. (2016). *Dyslexia: A practitioner's handbook* (5th ed.). Wiley-Blackwell.
- Reyes Wagnio, M. (2025). Microcredenciales en IA para la Educación: MC1 IA Generativa, MC2 IA Agéntica y MC3 IA para la Evaluación y la Analítica del Aprendizaje [Documento de diseño instruccional]. Universidad Bolivariana del Ecuador.
- Reyes Wagnio, M., & Rumbaut Rangel, D. (2025). Diseño curricular de la Maestría en Inteligencia Artificial para la Educación (IAEd): Líneas de investigación,

microcredenciales y perfil de egreso [Documento institucional]. Universidad Bolivariana del Ecuador.

Salazar Vega, L. R., et al. (2025). Análisis del uso de la inteligencia artificial para la detección temprana de dificultades de aprendizaje. *South Florida Journal of Development*, 6(9), 1–13. <https://doi.org/10.46932/sfjdv6n9-032>

Smarandache, F. (2005). *A unifying field in logics: Neutrosophic logic* (5th ed.). American Research Press.

Susana, E., Aucancela, E., Valeria, R., & Lozano, S. (2025). La educación inclusiva frente a las dificultades del lenguaje. *Ciencia Latina Revista Científica Multidisciplinar*, 9(5). https://doi.org/10.37811/cl_rcm.v9i5.20359

Zugarramurdi, C., et al. (2019). Valor predictor y discriminante de la velocidad de nombrado en español. *Ocnos. Revista de Estudios sobre Lectura*, 18(2). https://doi.org/10.18239/ocnos_2019.18.2.1812