

FACTORES SOCIO-EDUCATIVOS ASOCIADOS AL LOGRO EN MATEMÁTICAS: UN ENFOQUE DE ANALÍTICA DEL APRENDIZAJE CON INTELIGENCIA ARTIFICIAL PARA LA IDENTIFICACIÓN DE BRECHAS EDUCATIVAS EN ECUADOR

SOCIO-EDUCATIONAL FACTORS ASSOCIATED WITH ACHIEVEMENT IN MATHEMATICS: AN ARTIFICIAL INTELLIGENCE-BASED LEARNING ANALYTICS APPROACH FOR IDENTIFYING EDUCATIONAL GAPS IN ECUADOR

Alvaro Andrés Auquilla Ordóñez¹, Manuel Reyes Wagnio², Dayron Rumbaut Rangel³, María José Chávez Villacrés⁴

{aaaauquilla@ube.edu.ec¹, mfreyesw@ube.edu.ec², drumbautr@ube.edu.ec³, mj.chavezv@uea.edu.ec⁴}

Fecha de recepción: 29/05/2026 / Fecha de aceptación: 03/07/2026 / Fecha de publicación: 08/07/2026

RESUMEN: Este estudio aplica un enfoque de Analítica del Aprendizaje (Learning Analytics) basado en técnicas estadísticas propias de la Inteligencia Artificial para la Educación (IAEd) con el fin de identificar variables socio-educativas y administrativas asociadas al logro en matemáticas de 382 estudiantes ecuatorianos, a partir de datos del Instituto Nacional de Evaluación Educativa (INEVAL). Mediante la prueba de chi-cuadrado de Pearson (χ^2), se evaluó la asociación entre seis variables categóricas Régimen, Región, Provincia, Zona, Financiamiento y Subnivel Educativo y el nivel de logro matemático (Insuficiente, Elemental, Satisfactorio, Excelente). Los resultados revelaron la ausencia de asociación significativa para las variables geográficas y administrativas (Región, Provincia, Régimen, Zona; $p > 0.05$). No obstante, se encontró una asociación estadísticamente significativa entre el Tipo de Financiamiento ($\chi^2 = 23.48$, $gl = 9$, $p = 0.005$; V de Cramér = 0.143) y el Subnivel Educativo ($\chi^2 = 43.83$, $gl = 9$, $p = 1.52 \times 10^{-6}$; V de Cramér = 0.196) con el logro en matemáticas. Ambas asociaciones son de magnitud pequeña a moderada según los criterios de Cohen. Desde la perspectiva de la IAEd, estos hallazgos constituyen la fase exploratoria de un pipeline de Analítica del Aprendizaje: identifican las variables con mayor poder predictivo sobre el logro y establecen la base empírica para el desarrollo futuro de modelos de machine learning orientados a la detección temprana de estudiantes en riesgo y al diseño de intervenciones curriculares basadas en evidencia.

¹Universidad Bolivariana del Ecuador, Durán Ecuador, <https://orcid.org/0000-0001-6846-3536>

²Universidad Bolivariana del Ecuador, Durán Ecuador, <https://orcid.org/0000-0002-3102-0034>

³Universidad Bolivariana del Ecuador, Durán Ecuador, <https://orcid.org/0009-0001-9087-0979>

⁴Universidad Estatal Amazónica, Facultad Modalidad en Línea, Puyo, Ecuador, <https://orcid.org/0009-0000-0039-1601>

Palabras clave: *Logro en Matemáticas, analítica del aprendizaje, inteligencia artificial para la educación, chi-cuadrado, V de Cramér, financiamiento educativo, subnivel educativo, equidad educativa, Ecuador*

ABSTRACT: This study applies a Learning Analytics approach grounded in Artificial Intelligence for Education (AIEd) techniques to identify socio-educational and administrative variables associated with mathematics achievement among 382 Ecuadorian students, using data from the National Institute of Educational Evaluation (INEVAL). Pearson's chi-squared test (χ^2) was used to assess the association between six categorical variables —Regime, Region, Province, Zone, Funding, and Educational Sublevel— and mathematics achievement (Insufficient, Elementary, Satisfactory, Excellent). The results revealed the absence of a significant association for geographical and administrative variables (Region, Province, Regime, Zone; $p > 0.05$). However, a statistically significant association was found between the Type of Funding ($\chi^2 = 23.48$, $df = 9$, $p = 0.005$; Cramér's $V = 0.143$) and the Educational Sublevel ($\chi^2 = 43.83$, $df = 9$, $p = 1.52 \times 10^{-6}$; Cramér's $V = 0.196$) with mathematics achievement. Both associations are of small-to-moderate magnitude according to Cohen's criteria. From an AIEd perspective, these findings represent the exploratory phase of a Learning Analytics pipeline: they identify the variables with the greatest predictive power over achievement and establish the empirical basis for developing future machine learning models aimed at early detection of at-risk students and evidence-based curricular interventions.

Keywords: *Mathematics achievement, learning analytics, artificial intelligence for education, chi-squared, Cramér's V, educational funding, educational sublevel, educational equity, Ecuador*

INTRODUCCIÓN

El rendimiento académico en matemáticas es un indicador fundamental de la calidad educativa y una variable predictora crucial del éxito profesional y personal de los estudiantes. En el marco de la Inteligencia Artificial para la Educación (IAEd), la Analítica del Aprendizaje (Learning Analytics) emerge como una disciplina que permite transformar grandes volúmenes de datos educativos en conocimiento accionable para la mejora de los procesos de enseñanza-aprendizaje (1). En el contexto ecuatoriano, aplicar estas herramientas para comprender los factores que influyen en el logro matemático es esencial para orientar las políticas públicas y las estrategias pedagógicas hacia la reducción de brechas de equidad.

La literatura educativa global ha identificado una compleja red de factores que interactúan con el logro del estudiante, desde variables socioeconómicas hasta el contexto institucional y curricular. Desde la perspectiva de la Analítica del Aprendizaje, el análisis estadístico de estas variables constituye la fase exploratoria y descriptiva de un pipeline de IAEd: permite seleccionar los predictores con mayor poder de discriminación antes de avanzar hacia modelos supervisados de machine learning orientados a la clasificación o predicción del logro (2). El presente estudio se

inserta en esta fase inicial, proporcionando evidencia empírica sobre qué variables del sistema educativo ecuatoriano se asocian significativamente con el logro matemático.

En el Ecuador, la evidencia empírica disponible sobre el logro matemático proviene fundamentalmente de las evaluaciones del Instituto Nacional de Evaluación Educativa (INEVAL), en particular de las pruebas Ser Estudiante, que miden el desempeño en cuatro niveles de logro (Insuficiente, Elemental, Satisfactorio y Excelente) a lo largo de los distintos subniveles del sistema (3). La participación del Ecuador en PISA-D (Programme for International Student Assessment para Países en Desarrollo) ha añadido una dimensión comparativa internacional que refuerza la urgencia de comprender los determinantes del rendimiento matemático. En este marco, (4) demostraron que el nivel socioeconómico y la calidad de la educación inicial se asocian significativamente con el logro en matemáticas en primaria ecuatoriana, mientras que (5), en su análisis de los resultados de la evaluación nacional estudiantil de 2018, evidenciaron brechas persistentes entre tipos de establecimiento y regiones del país. Estos antecedentes justifican el enfoque del presente estudio y orientan la selección de las variables de financiamiento y subnivel educativo como predictores clave.

Este estudio se justifica en la necesidad de: (a) aplicar técnicas de Analítica del Aprendizaje al contexto educativo ecuatoriano para identificar variables predictoras del logro matemático con base en datos reales del sistema INEVAL; (b) interpretar pedagógicamente la relevancia de las asociaciones encontradas (Financiamiento y Subnivel) y la ausencia de asociación en variables geográficas (Región, Provincia, Régimen, Zona), con implicaciones directas en la eficacia y equidad de las políticas educativas descentralizadas; y (c) establecer una base empírica para el desarrollo de modelos predictivos de IAEd que en etapas futuras permitan la detección temprana de estudiantes en riesgo y el diseño de intervenciones personalizadas basadas en IA.

Los objetivos del estudio son los siguientes. Objetivo general: determinar y discutir la asociación estadísticamente significativa de variables socio-educativas y administrativas (Región, Provincia, Régimen, Zona, Financiamiento y Subnivel) con el logro en matemáticas de una muestra de estudiantes ecuatorianos, cuantificar la magnitud de las asociaciones mediante el coeficiente V de Cramér, e interpretar sus implicaciones pedagógicas y políticas. Objetivos específicos: (1) Contrastar las hipótesis nulas de no asociación entre las seis variables categóricas seleccionadas y el logro en matemáticas mediante la prueba de chi-cuadrado de Pearson con $\alpha = 0.05$; (2) cuantificar la magnitud de las asociaciones significativas mediante el coeficiente V de Cramér; (3) analizar las distribuciones de frecuencia de las tablas de contingencia para identificar patrones de logro específicos en función del tipo de financiamiento y el subnivel educativo; (4) interpretar pedagógicamente los patrones de logro por subnivel con énfasis en la polarización en Básica Elemental y el estancamiento en Bachillerato; y (5) formular propuestas de acción educativa y futuras líneas de investigación basadas en los hallazgos de asociación significativa.

La Analítica del Aprendizaje (Learning Analytics) se define como la medición, recolección, análisis e informe de datos sobre los estudiantes y sus contextos, con el propósito de comprender y optimizar el aprendizaje y los entornos en los que ocurre (1). En el marco de la IAEd, este campo abarca desde métodos estadísticos clásicos hasta técnicas avanzadas de machine learning como árboles de decisión, redes neuronales o modelos de regresión logística, todos orientados a

identificar patrones en datos educativos que permitan predecir resultados, detectar estudiantes en riesgo y personalizar intervenciones (2). El presente estudio se ubica en la capa exploratoria de este pipeline: emplea la prueba χ^2 como técnica de selección de variables y cuantifica la magnitud de las asociaciones mediante el coeficiente V de Cramér, estableciendo las bases para etapas posteriores de modelado predictivo con IA.

El sistema educativo ecuatoriano se clasifica por variables geográficas (Costa, Sierra, Amazonía, Galápagos), administrativas (Régimen Escolar) y de sostenimiento o financiamiento (Fiscal, Fiscomisional, Municipal, Particular). Cada una de estas variables puede representar un clúster de condiciones socioeconómicas, inversión en infraestructura y calidad docente que influyen en el rendimiento.

Financiamiento (Sostenimiento): La brecha entre la educación pública (Fiscal) y la privada (Particular) ha sido ampliamente documentada a nivel global. Factores como la inversión per cápita, la autonomía curricular y la formación docente suelen ser mayores en el sector privado, lo que potencialmente se traduce en mejores resultados académicos (6; 7).

Subnivel Educativo: El logro en matemáticas no es estático; se espera que las competencias se desarrollen progresivamente. Analizar la asociación por subnivel (Básica Elemental, Básica Media, Básica Superior, Bachillerato) permite identificar en qué etapa de la trayectoria educativa se concentran las mayores deficiencias o los picos de excelencia, informando sobre la eficacia del currículo por etapas.

La prueba de χ^2 es una herramienta estadística no paramétrica utilizada para determinar si existe una asociación significativa entre dos variables categóricas (8). En este estudio, se contrasta la distribución observada del logro en matemáticas dentro de cada categoría de las variables predictoras (e.g., Financiamiento) con una distribución esperada bajo la hipótesis de independencia (Hipótesis Nula, H_0). Un valor p menor al nivel de significancia ($\alpha=0.05$) permite rechazar H_0 y concluir que existe una asociación estadísticamente significativa. Para las asociaciones significativas se calculó el coeficiente V de Cramér ($V = \sqrt{\chi^2 / (N \cdot k)}$, donde $k = \min(\text{filas}, \text{columnas}) - 1$) como medida del tamaño del efecto. Respecto a la verificación de supuestos, la prueba χ^2 requiere que al menos el 80 % de las frecuencias esperadas sea ≥ 5 y que ninguna celda presente frecuencia esperada igual a cero (9). Para las variables Financiamiento y Subnivel Educativo, 8 de 16 celdas (50 %) presentaron frecuencias esperadas menores a 5, debido principalmente a la escasez de casos en las categorías Excelente ($n = 4$) e Insuficiente ($n = 9$). Esta limitación debe tenerse en cuenta al interpretar los valores p reportados; estudios futuros con muestras más amplias deberían considerar el agrupamiento de categorías poco frecuentes.

MATERIALES Y MÉTODOS

2.1. Diseño del Estudio

Se adoptó un diseño de investigación no experimental, descriptivo y correlacional-asociativo con base en datos secundarios. El estudio se centra en establecer la existencia y magnitud de la

asociación entre un conjunto predefinido de variables categóricas, sin manipularlas ni establecer relaciones causales directas.

2.2. Fuentes de Datos y Muestra

Los datos provienen de la base de datos INEVAL, una muestra intencional de 382 observaciones de estudiantes ecuatorianos.

Variables Analizadas:

Variable Dependiente: Logro en Matemáticas (Categorías: Excelente, Satisfactorio, Elemental, Insuficiente).

Variables Predictoras: Región, Provincia, Régimen, Zona, Financiamiento (Sostenimiento), Subnivel Educativo.

2.3. Procesos de Análisis

El análisis estadístico se realizó mediante el siguiente procedimiento, ejecutado en un entorno de análisis de datos como lo es RStudio.

Definición de la Hipótesis: Para cada par de variables, se definió la hipótesis nula (H_0): "No existe asociación significativa entre la variable X y el Logro en Matemáticas".

1. **Construcción de Tablas de Contingencia:** Se generaron tablas de contingencia para cada par de variables, mostrando las frecuencias observadas y las proporciones marginales.
2. **Aplicación de la Prueba χ^2 de Pearson:** Se calculó el estadístico χ^2 y su correspondiente valor p para evaluar la independencia.
3. **Criterio de Decisión:** Se utilizó un nivel de significancia de $\alpha=0.05$. La decisión de rechazar H_0 se tomó si $p<0.05$.
4. **Análisis de Residuales (Interpretación de los Resultados):** Aunque el informe solo presenta la prueba general, la interpretación de los patrones de logro ("Insuficiente", "Excelente") en las tablas de contingencia se utilizó para entender la naturaleza de la asociación cuando fue significativa.

RESULTADOS

El análisis de la prueba χ^2 se presenta a continuación, contrastando cada variable predictora con la variable de logro en matemáticas.

3.1. Variables sin Asociación Significativa con el Logro en Matemáticas

Las variables geográficas y administrativas mostraron valores p consistentemente superiores a 0.05, lo que impide rechazar la hipótesis nula de no asociación.

Tabla 1. Conclusión estadística

Variable	χ^2 (gl)	Valor p-value	Conclusión Estadística ($\alpha=0.05$)
Región	5.659 (6)	0.462	No hay asociación significativa
Provincia	50.881 (63)	0.864	No hay asociación significativa
Régimen	5.286 (3)	0.152	No hay asociación significativa
Zona	15.974 (24)	0.889	No hay asociación significativa

Fuente: Adaptación de la Tabla de Contingencia del Informe Estadístico.

La falta de asociación significativa sugiere que, a nivel de la muestra, el logro en matemáticas no está determinado por la ubicación macro-geográfica o el régimen administrativo. Esto podría interpretarse como una posible equidad en la distribución del logro en función de estas grandes divisiones geográficas.




Figura 1. Distribución del Logro en Matemáticas por Tipo de Financiamiento (barras apiladas al 100 %)

3.2. Variables con Asociación Significativa con el Logro en Matemáticas

Dos variables clave mostraron una asociación estadísticamente significativa con el logro en matemáticas, lo que permite rechazar la hipótesis nula.

3.2.1. Financiamiento (Sostenimiento) - Logro en Matemáticas

Resultados del χ^2 :

$$\chi^2 = 23.48208$$

$$g.l. = 9$$

$$p = 0.00519979$$

$$V \text{ de Cramér} = 0.143 \text{ (efecto pequeño)}$$

Dado que $p < 0.05$, se concluye que existe una asociación significativa de efecto pequeño ($V = 0.143$) entre el tipo de financiamiento y el logro en matemáticas.

Tabla 2. Frecuencias y Contribuciones Observadas de Financiamiento vs. Logro en Matemáticas (N=382).

Financiamiento	Elemental	Excelente	Insuficiente	Satisfactorio	Total
Fiscal	90	3	5	43	141
Fiscomisional	55	1	2	35	93
Municipal	36	0	1	9	46
Particular	47	0	1	54	102
Total	228	4	9	141	382

Fuente: Adaptación de la Tabla de Contingencia del Informe Estadístico.

El sector Particular (102 estudiantes) muestra una concentración desproporcionadamente alta en el nivel "Satisfactorio" (54 estudiantes). En contraste, el sector Fiscal (141 estudiantes), a pesar de ser la categoría con más observaciones, tiene una mayor concentración en "Elemental" (90 estudiantes) y menos en "Satisfactorio" en proporción a la matrícula total. Esta disparidad es la principal contribuyente a la asociación significativa.




Figura 2. Distribución del Logro en Matemáticas por Subnivel Educativo (barras apiladas al 100 %)

3.2.2. Subnivel Educativo - Logro en Matemáticas

Resultados del χ^2 :

$$\chi^2 = 43.82997$$

$$g.l. = 9$$

$$p = 1.516984 \times 10^{-6}$$

$$V \text{ de Cramér} = 0.196 \text{ (efecto pequeño-moderado)}$$

El valor p extremadamente bajo (cercano a cero) indica una asociación altamente significativa de efecto pequeño-moderado ($V = 0.196$) entre el subnivel educativo y el logro en matemáticas.

Tabla 3. Frecuencias y Contribuciones Observadas de Subnivel vs. Logro en Matemáticas (N=382).

Subnivel	Elemental	Excelente	Insuficiente	Satisfactorio	Total
Bachillerato	66	0	0	27	93
Básica Elemental	51	4	8	37	100
Básica Media	72	0	1	34	107
Básica Superior	39	0	0	43	82

Total	228	4	9	141	382
-------	-----	---	---	-----	-----

Fuente: Adaptación de la Tabla de Contingencia del Informe Estadístico.

La asociación significativa refleja la naturaleza progresiva del aprendizaje. El Subnivel Básica Elemental es el único que concentra un número notable de estudiantes en el nivel "Excelente" (4 estudiantes), pero también es el que tiene la mayor cantidad de estudiantes en "Insuficiente" (8 estudiantes), lo que sugiere una mayor polarización del rendimiento en las etapas iniciales. El Nivel Bachillerato tiene una ausencia de estudiantes en los niveles "Excelente" e "Insuficiente", concentrándose fuertemente en "Elemental" y "Satisfactorio".

Los resultados de este estudio ofrecen una visión matizada de la equidad y la progresión del aprendizaje en matemáticas, contrastando la aparente homogeneidad geográfica con las profundas disparidades institucionales y curriculares.




Figura 3. Distribución general del logro en matemáticas en la muestra (sin asociación geográfica significativa)

DISCUSIÓN

Implicaciones de la No-Asociación Geográfica (Región, Provincia, Régimen, Zona)

La conclusión de que la Región, Provincia, Régimen y Zona no están significativamente asociadas con el logro en matemáticas ($p > 0.05$) es un hallazgo que merece una interpretación cautelosa:

Positiva (Equidad): Podría interpretarse como un éxito en la estandarización y equidad de las políticas curriculares y de infraestructura a nivel nacional, donde las grandes divisiones geográficas (Costa vs. Sierra) no representan, en sí mismas, una barrera al rendimiento. El sistema asegura, en términos generales, un nivel de logro similar independientemente de la ubicación. Este hallazgo es coherente con estudios comparativos que documentan que, en sistemas educativos con políticas de equidad consolidadas, la segregación geográfica puede atenuarse aunque persistan brechas institucionales (10; 11).

Limitación (Dilución del Contexto): Alternativamente, la prueba χ^2 solo detecta una asociación general. Los efectos del contexto geográfico podrían estar enmascarados por la naturaleza de las categorías. Un análisis de regresión multinivel, que incluya variables socioeconómicas específicas de cada provincia o zona, probablemente revelaría efectos contextuales que la prueba bivariada categórica no logra capturar (12).

Disparidad por Financiamiento: La Brecha Educativa Institucional

La asociación altamente significativa entre el Tipo de Financiamiento y el logro en matemáticas ($\chi^2 = 23.48$, $gl = 9$, $p = 0.005$; V de Cramér = 0.143) es el resultado más crítico en términos de política educativa y equidad. En el contexto latinoamericano, la diferencia de resultados entre establecimientos públicos y privados ha sido documentada consistentemente mediante análisis PISA-D (13; 14; 15), y la evidencia internacional muestra que la inversión por estudiante guarda una relación positiva con el logro académico (16):

Evidencia de Brecha: La mayor proporción de estudiantes en el nivel "Satisfactorio" en establecimientos Particulares sugiere que el acceso a mejores resultados académicos está, en parte, mediado por el sector de financiamiento.

Factores Pedagógicos Hipotéticos: Esta diferencia podría deberse a:

- Inversión de Recursos: Mayor inversión en tecnología, materiales didácticos especializados, y mantenimiento de infraestructura en el sector particular.
- Formación Docente: Mayor autonomía y presupuesto para la capacitación continua y especializada de los docentes en matemáticas.
- Contexto Socioeconómico: Aunque no se mide directamente, el sector particular a menudo matricula a estudiantes de estratos socioeconómicos más altos, lo que confiere ventajas en apoyo familiar, acceso a tutorías y recursos en el hogar (17; 7; 18).

Progresión del Aprendizaje: Desafíos por Subnivel Educativo

La asociación muy fuerte con el Subnivel Educativo ($\chi^2 = 43.83$, $gl = 9$, $p = 1.52 \times 10^{-6}$; V de Cramér = 0.196) valida que el logro en matemáticas es un constructo que varía fundamentalmente con la madurez y la etapa curricular del estudiante, hallazgo consistente con investigaciones que documentan la desigualdad de competencias a lo largo de la trayectoria escolar en América Latina (19; 20), pero también resalta desafíos específicos:

Polarización Temprana: La coexistencia de picos de "Excelente" e "Insuficiente" en Básica Elemental sugiere que las bases del aprendizaje matemático se establecen muy temprano, y las intervenciones (o la falta de ellas) en esta etapa tienen un impacto dramático y polarizante en la trayectoria académica futura. Una sólida instrucción en pensamiento lógico y resolución de problemas en este subnivel es crucial.

Estancamiento en Bachillerato: La alta concentración en "Elemental" y "Satisfactorio" y la ausencia de "Excelentes" en el Nivel Bachillerato es preocupante. Esto podría indicar un estancamiento en el desarrollo de competencias avanzadas o una desconexión entre el currículo de matemáticas de Bachillerato y las motivaciones o habilidades de los estudiantes, limitando su potencial para estudios superiores en STEM (Ciencia, Tecnología, Ingeniería y Matemáticas), además de un posible efecto de selección acumulativo en el que los estudiantes con mayores dificultades desertan antes de llegar a este nivel, reduciendo la varianza del rendimiento sin que ello implique una mejora real de competencias (21; 22; 23).

Análisis de Casos Atípicos (Loja y Orellana)

A pesar de que la variable Provincia no fue significativa a nivel general, los patrones reportados para Loja (alto desempeño en "Excelente") y Orellana (alto desempeño en "Insuficiente") actúan como casos atípicos que merecen una investigación cualitativa profunda. Estos extremos sugieren la existencia de factores locales (endógenos) muy potentes (e.g., programas de apoyo, liderazgo directivo, metodologías de enseñanza innovadoras) que la generalidad estadística no logra dilucidar.

CONCLUSIONES

El análisis realizado en este artículo permite identificar dos hallazgos primordiales con profundas implicaciones para la política educativa matemática en Ecuador: Equidad Geográfica a Nivel General: La ausencia de una asociación significativa entre el logro en matemáticas y las variables geográficas/administrativas amplias (Región, Provincia, Régimen, Zona) sugiere que las disparidades en el rendimiento se originan en factores más localizados, institucionales o pedagógicos, y no en la ubicación macro-geográfica.

Disparidad Institucional y Curricular Clave:

Financiamiento: Existe una asociación significativa de efecto pequeño entre el Tipo de Financiamiento ($\chi^2 = 23.48$, $gl = 9$, $p = 0.005$; V de Cramér = 0.143) y el logro, evidenciando una brecha de calidad y recursos entre los establecimientos particulares y los fiscales.

Subnivel Educativo: La asociación altamente significativa con el Subnivel ($\chi^2 = 43.83$, $gl = 9$, $p = 1.52 \times 10^{-6}$; V de Cramér = 0.196) confirma que el rendimiento está intrínsecamente ligado a la etapa educativa, con desafíos de polarización en Básica Elemental y estancamiento en Bachillerato.

Con base en estos hallazgos, se proponen las siguientes recomendaciones de política educativa e investigación en IAEd: (1) fortalecer la formación continua de docentes de matemáticas en el sector fiscal, con énfasis en metodologías activas y uso de tecnología educativa; (2) diseñar intervenciones curriculares específicas para Básica Elemental orientadas a reducir la polarización del rendimiento; (3) revisar el currículo de matemáticas de Bachillerato para incorporar desafíos cognitivos que estimulen competencias avanzadas; (4) implementar sistemas de monitoreo formativo por subnivel que permitan identificar oportunamente a estudiantes en riesgo; y (5) desarrollar en etapas futuras modelos predictivos de machine learning como árboles de decisión, Random Forest o redes neuronales que, utilizando Financiamiento y Subnivel Educativo como variables de entrada prioritarias, permitan predecir el nivel de logro matemático individual y personalizar intervenciones pedagógicas con IA. Estas investigaciones deben ampliar la muestra con criterios probabilísticos e incorporar variables de contexto socioeconómico para aumentar la potencia y generalidad de los modelos.

El presente estudio tiene tres limitaciones fundamentales que deben declararse con claridad. En primer lugar, la muestra intencional de 382 casos constituye la restricción más seria: al no ser probabilística, los resultados no son generalizables al universo de estudiantes ecuatorianos y deben interpretarse con cautela. En segundo lugar, el diseño bivariado no permite establecer relaciones causales ni controlar variables de confusión relevantes, como el nivel socioeconómico familiar, la experiencia docente o el tipo de currículo implementado en cada establecimiento. En tercer lugar, la violación parcial del supuesto de frecuencias esperadas ≥ 5 (50 % de celdas afectadas en las tablas correspondientes a las variables significativas, principalmente por la escasez de casos en las categorías Excelente [$n = 4$] e Insuficiente [$n = 9$]) reduce la fiabilidad exacta de los valores p reportados para χ^2 ; estudios futuros con muestras más amplias deberían considerar el agrupamiento de categorías poco frecuentes o el uso de la prueba exacta de Fisher para tablas con celdas de frecuencia baja.

AGRADECIMIENTOS (OPCIONAL)

A la Universidad Bolivariana del Ecuador.

DECLARACIÓN DE INTERÉS (OPCIONAL)

Los autores de este documento manifiestan no presentar ningún conflicto de intereses.

REFERENCIAS BIBLIOGRÁFICAS

1. Agasisti, T., & Zoido, P. (2018). Efficiency and equity in European education and training systems. *European Journal of Education*, 53(4), 475-490. <https://doi.org/10.1111/ejed.12306>
2. Antequera, J. A. (2019). Eficiencia educativa en escuelas públicas y privadas de América Latina: Un análisis comparativo mediante PISA-D. *Revista de Educación*, 385, 28-53.

3. Arias Ortiz, E., Bottan, N., & Cristia, J. (2024). *Learning can't wait: Lessons for Latin America and the Caribbean from PISA 2022*. Inter-American Development Bank. <https://publications.iadb.org>
4. Bojorque, G., Torbeyns, J., Van Nijlen, D., & Verschaffel, L. (2018). The contribution of SES, quality of early mathematics education, and school readiness to mathematics achievement in Ecuador. *Educational Psychology*, 38(8), 1063-1080. <https://doi.org/10.1080/01443410.2018.1462296>
5. Bonal, X., & Bellei, C. (2020). *Understanding school segregation: Patterns, causes and consequences of spatial inequalities in education*. Bloomsbury Academic.
6. Bos, M. S., Ganimian, A. J., & Vegas, E. (2019). *Learning in Ecuador's schools: A summary of results from the 2018 National Student Assessment*. Inter-American Development Bank.
7. Brunner, J. J., & Cox, C. (2011). *Conflicto de intereses: Escuelas particulares y escuelas públicas*. Ediciones Universidad Diego Portales.
8. Carnoy, M. (2007). The impact of private schools on educational attainment and achievement: A multi-country analysis. *Educational Research Review*, 2(1), 1-21. <https://doi.org/10.1016/j.edurev.2007.03.001>
9. Castro Aristizabal, G., León, M., & Zakzuk, N. (2017). Brechas de logro entre escuelas públicas y privadas en América Latina: Evidencia de PISA 2012. *Revista de Economía del Rosario*, 20(2), 153-178.
10. Choi, B. (2025). *Socioeconomic status and its relationship to mathematics achievement: Using a meta-analysis* [Doctoral dissertation, University of New Hampshire]. Scholars' Repository. <https://scholars.unh.edu/dissertation/2904/>
11. Chudgar, A., & Luschei, T. F. (2009). National income, income inequality, and the gender gap in higher education. *Comparative Education Review*, 53(1), 1-23. <https://doi.org/10.1086/593152>
12. Delprato, M., & Antequera, J. A. (2021). Efficiency gaps between private and public schools in Latin America: Evidence from PISA-D. *International Journal of Educational Development*, 85, 102454. <https://doi.org/10.1016/j.ijedudev.2021.102454>
13. De La O, A., Elacqua, G., & Martínez, M. (2023). School segregation and academic achievement in Latin America. *Journal of Human Resources*, 58(4), 1123-1156.
14. García-Huidobro, C. (2007). Desigualdad educativa y la brecha en el logro: Evidencia y políticas en América Latina. *Revista Latinoamericana de Estudios Educativos*, 37(1-2), 1-28.
15. Hanushek, E. A. (2020). Education production functions. In S. Bradley & C. Green (Eds.), *The economics of education* (2nd ed., pp. 161-170). Academic Press.
16. Learning Policy Institute. (2025). *How money matters: Education funding and student outcomes*. <https://learningpolicyinstitute.org/product/how-money-matters-factsheet>
17. McHugh, M. L. (2013). The chi-square test of independence. *Biochemia Medica*, 23(2), 143-149. <https://doi.org/10.11613/BM.2013.018>
18. Naslund-Hadley, E., & Alonzo, H. (2019). *How unequal is learning in Latin America? An analysis of socioeconomic and indigenous skill gaps* (CIMA Brief No. 27). Inter-American Development Bank. <https://publications.iadb.org>

19. Papamitsiou, Z., & Economides, A. A. (2014). Learning analytics and educational data mining in practice: A systematic literature review of empirical evidence. *Journal of Educational Technology & Society*, 17(4), 49–64.
20. Raudenbush, S. W., & Bryk, A. S. (2002). *Hierarchical linear models: Applications and data analysis methods (2nd ed.)*. SAGE Publications.
21. Siegel, S., & Castellan, N. J. (1988). *Nonparametric statistics for the behavioral sciences (2nd ed.)*. McGraw-Hill.
22. Siemens, G., & Baker, R. S. (2012). *Learning analytics and educational data mining: Towards communication and collaboration*. Proceedings of the 2nd International Conference on Learning Analytics and Knowledge, 252-254.
23. Valverde, G. A., & Viteri, M. F. (2016). *Factores de éxito en las pruebas PISA en el contexto educativo ecuatoriano*. *Revista de Ciencias Sociales*, 22(3), 11-25.