

Research Article

Modelos predictivos para medir la eficiencia del juego matemático inclusivo en estudiantes de la unidad educativa “Manuela Cañizares”, Orellana

Predictive models to measure the efficiency of inclusive mathematical games in students of the educational unit 'Manuela Cañizares', Orellana

Bonilla-Vimos, Washington Ramiro ¹<https://orcid.org/0009-0004-8065-0456>washington.bonilla@esepoch.edu.ecEscuela Superior Politécnica de Chimborazo,
Ecuador, RiobambaLogroño-Naranjo, Santiago Israel ²<https://orcid.org/0000-0002-1205-3017>santiago.logronio@esepoch.edu.ecEscuela Superior Politécnica de Chimborazo,
Ecuador, RiobambaAutor de correspondencia ¹DOI / URL: <https://doi.org/xxxxxx>

Resumen: La educación inclusiva es clave para garantizar que todos tengan la oportunidad de aprender de manera justa, pero los estudiantes con necesidades especiales a menudo enfrentan desafíos significativos, especialmente en matemáticas. Esta investigación se enfoca en evaluar la efectividad de un juego matemático inclusivo en la Unidad Educativa "Manuela Cañizares" de Orellana, creado específicamente para estudiantes con necesidades especiales. Se utilizó un enfoque cuantitativo y un diseño cuasi-experimental de tipo pretest–posttest, aplicando la metodología CRISP-DM para gestionar los datos. La muestra incluyó a 124 estudiantes con necesidades especiales, y se analizaron en profundidad variables como la edad, el tipo de necesidad especial, el nivel educativo, la asistencia, los intentos en el juego y la motivación. Se emplearon modelos de regresión logística y análisis de series temporales para evaluar el impacto del juego en el rendimiento académico. Los resultados mostraron una mejora del 25% en las habilidades matemáticas y una correlación positiva significativa entre la motivación y el desempeño de los estudiantes. Además, el modelo predictivo alcanzó un 96% de precisión, lo que respalda su efectividad para anticipar el progreso académico. En conclusión, la combinación de gamificación y modelos predictivos en la educación inclusiva representa una estrategia innovadora y efectiva, y se recomienda su implementación en diversos contextos, así como la capacitación de los docentes en metodologías pedagógicas adaptativas.

Palabras clave: modelos predictivos, educación inclusiva, juego matemático, necesidad especial intelectual, aprendizaje adaptativo.

Check for
updates**Received:** 22/Ago/2025**Accepted:** 11/Sep/2025**Published:** 31/Oct/2025

Cita: Bonilla-Vimos, W. R., & Logroño-Naranjo, S. I. (2025). Modelos predictivos para medir la eficiencia del juego matemático inclusivo en estudiantes de la unidad educativa "Manuela Cañizares", Orellana. *Journal of Economic and Social Science Research*, 5(4), 39-52. <https://doi.org/10.55813/gaea/jessr/v5/n4/216>

Journal of Economic and Social Science Research (JESSR)
<https://economicsocialresearch.com>
info@editoriagrupo-aea.com

Nota del editor: Editorial Grupo AEA se mantiene neutral con respecto a las reclamaciones legales resultantes de contenido publicado. La responsabilidad de información publicada recae enteramente en los autores.

© 2025. Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons. Atribución-NoComercial 4.0 Internacional**.



Abstract:

Inclusive education is an important factor to ensuring that everyone has the opportunity to learn fairly, but students with disabilities often face significant challenges, especially in mathematics. The current research focuses on evaluating the effectiveness of an inclusive math game at “Unidad Educativa Manuela Cañizares”, located in Orellana province which was created specifically for students with disabilities. It used a quantitative approach and a pretest-posttest quasi-experimental design; applying the CRISP-DM methodology to manage the data. To start, the sample included 124 students with disabilities with variables such as: age, type of disability, educational level, attendance, attempts in the game, and motivation were analyzed further. On the other hand, logistic regression models and time series analysis were used to assess the impact of the game on academic performance. The results showed a 25% improvement in math skills and a significant positive correlation between motivation and student performance. In addition, the predictive model achieved 96% accuracy, supporting its effectiveness in anticipating academic progress. In conclusion, the combination of gamification and predictive models in inclusive education represents an innovative and effective strategy, and its implementation in various contexts is recommended; as well as the training of teachers in adaptive pedagogical methodologies.

Keywords: predictive models, inclusive education, math game, intellectual disability, adaptive learning.

1. Introducción

La educación inclusiva se ha convertido en un derecho fundamental, con el objetivo de garantizar que todos los estudiantes, sin importar sus habilidades individuales, tengan acceso a una educación justa y de calidad (Rodríguez-García & Arias-Gago, 2022). Sin embargo, no se puede negar que los estudiantes con necesidades especiales enfrentan retos importantes en su proceso de aprendizaje ya que son capaces de responder de forma equitativa a la heterogeneidad de necesidades educativas específicas que presentan muchos estudiantes. (Michuy-Guingla et al., 2025)., especialmente en matemáticas, donde los métodos de enseñanza tradicionales a menudo no se adaptan a sus necesidades específicas (Screpnik, Cabrera & Neira, 2023).

Esta situación se complica aún más en áreas rurales, como se observa en la Unidad Educativa "Manuela Cañizares" en Orellana, donde la falta de recursos y la escasa formación de los docentes especializados dificultan la implementación de estrategias de enseñanza personalizadas. Después de años observando cómo algunos estudiantes luchan con las matemáticas mientras otros parecen comprenderlas sin esfuerzo, he llegado a una conclusión respaldada por investigación sólida,

necesitamos cambiar radicalmente nuestra manera de enseñar números. Los juegos matemáticos inclusivos no son solo una moda pasajera. Como demuestran (Ramani, Purpura & Cirino, 2020), representan una alternativa genuinamente innovadora para desarrollar habilidades numéricas mientras creamos entornos de aprendizaje más equitativos.

He visto de primera mano cómo un estudiante que se consideraba "malo para las matemáticas" de repente se ilumina cuando los números se presentan como un desafío divertido. La gamificación funciona porque aprovecha algo fundamental en la naturaleza humana: nuestro amor por el juego. Zambrano, C. B. (2025), confirma lo que muchos educadores intuimos: cuando incorporamos elementos lúdicos en la enseñanza, especialmente para estudiantes con necesidades educativas especiales, la motivación se dispara y con ella el rendimiento académico. La evidencia es contundente. (Bang et al., 2022), los juegos educativos han documentado al incorporar elementos propios del diseño como puntos, medallas, tablas de clasificación, niveles, avatares o retos personalizados convierte las actividades escolares en experiencias más atractivas (Concha-Ramirez et al., 2023) y mejoran la retención del conocimiento, sino que transforman a los estudiantes en participantes activos de su propio aprendizaje matemático. Ya no son receptores pasivos, sino exploradores curiosos.

Pero hay algo aún más emocionante en el horizonte. Los modelos predictivos, como explica (Velasategui, 2023), nos están dando una ventana hacia el futuro del aprendizaje. Podemos identificar patrones que antes pasaban desapercibidos y anticipar qué estudiantes necesitarán apoyo antes de que se queden atrás. Estamos en territorio nuevo aquí. Aunque (Durairaj & Vijitha, 2014; Arcila Calderón, 2019), nos recuerdan que estamos en etapas iniciales, el potencial es innegable. La combinación de juegos inclusivos y tecnología predictiva podría personalizar la educación de una manera revolucionaria, donde cada estudiante tenga un camino diseñado específicamente para sus necesidades y fortalezas.

En este contexto, este estudio tiene como objetivo evaluar la efectividad de un juego matemático inclusivo mediante el uso de modelos predictivos, aplicando técnicas de regresión logística y análisis de series temporales. Entre sus metas específicas se incluyen identificar las habilidades matemáticas iniciales de los estudiantes, diseñar el juego inclusivo, implementar técnicas avanzadas de ciencia de datos y evaluar el impacto del juego a través de métricas validadas. Se espera que los resultados proporcionen evidencia científica que respalde la efectividad de los juegos matemáticos en el aprendizaje de estudiantes con necesidades especiales, además de permitir el diseño de estrategias basadas en evidencia para mejorar la educación inclusiva en entornos vulnerables.

Los principios del constructivismo y la teoría del aprendizaje inclusivo proporcionan el fundamento para el diseño de estrategias educativas que fomentan la participación activa y equitativa de todos los estudiantes en el proceso de aprendizaje (Del Campo, López & Sanabria, 2017), este trabajo busca responder a la pregunta: ¿Cómo pueden


los modelos predictivos evaluar la efectividad de un juego matemático inclusivo en el desarrollo de habilidades matemáticas en estudiantes con necesidades especiales?.

2. Materiales y métodos

Se llevo a cabo esta investigación, decidimos usar un método que nos permitiera medir resultados concretos. Trabajamos con un diseño que compara el 'antes y después', es decir evaluamos a los estudiantes antes de usar el juego matemático inclusivo y luego volvimos a evaluarlos después. La idea era poder ver de manera clara si este tipo de herramientas realmente ayuda a los estudiantes con necesidades especiales a mejorar en matemáticas inclusivo en estudiantes con necesidades especiales. Elegimos este enfoque porque queríamos datos sólidos que pudieran demostrar si nuestra propuesta funciona o no en la práctica.

Se empleó la metodología CRISP-DM (Cross Industry Standard Process for Data Mining), reconocida por constituir de forma sistemática y estructurada proyectos de ciencia de datos (Chapman et al., 2000).

Figura 1
Fases del ciclo CRISP-DM.



Nota: Fases del ciclo CRISP-DM aplicadas en la evaluación del juego matemático inclusivo (Autores, 2025).

Comprensión del Negocio:

En la Unidad Educativa "Manuela Cañizares" de Orellana, nos propusimos algo ambicioso pero necesario. Queríamos descubrir si un juego matemático diseñado con verdadera inclusión podría transformar la experiencia de aprendizaje para estudiantes con diferentes necesidades especiales. La realidad que enfrentamos a diario es compleja. Las estrategias tradicionales que usamos en clase simplemente no funcionan para todos nuestros estudiantes. Y en nuestra provincia, los recursos tecnológicos y especializados son escasos y no aplicados.

Esto nos llevó a preguntarnos ¿Qué pasaría si creáramos algo diferente?. Nuestro objetivo es desarrollar un juego con herramientas que permitan predecir cómo nuestros estudiantes podrían responder académicamente, entendiendo a cada niño exactamente lo que necesitan con esta propuesta pedagógica innovadora, dándoles una respuesta urgente y ofrecerles una educación más justa y efectiva.

Comprensión de los Datos:

Para el análisis se recopilaron variables de distinta naturaleza. En el ámbito demográfico se consideraron la edad y el nivel educativo. En el aspecto académico se incluyeron la calificación inicial en matemáticas, la asistencia a clases, el número de intentos en el juego la mejora del aprendizaje. Finalmente, en el ámbito psicoeducativo se tomaron en cuenta la motivación y el tipo de necesidad especial, de acuerdo con la clasificación establecida en el Manual Diagnóstico y Estadístico de los Trastornos Mentales (DSM-5).

Las variables cuantitativas se registraron en escalas numéricas (continuas o discretas), mientras que las cualitativas se midieron en escalas nominales y ordinales. La información se obtuvo a través de instrumentos digitales de evaluación, pruebas diagnósticas aplicadas a 124 estudiantes con necesidades especiales, elegidos mediante un muestreo intencional para garantizar la inclusión de diversos tipos de necesidad especial para abarcar distintos niveles educativos y registros automáticos generados por el software del juego (ver Tabla 1).

Tabla 1
Descripción de variables

Variable	Tipo de Variable	Descripción	Escala de medición
Edad	Cuantitativa	Edad del estudiante	Númerica continua
Tipo de necesidades especiales	Cualitativa	Clasificación según DSM-5	Nominal (visual, auditiva, etc.)
Nivel educativo	Cualitativa	Grado escolar	Ordinal (Básica, Básica Superior, Bachillerato)
Calificación inicial	Cuantitativa	Resultado de evaluación diagnóstica	Númerica (0–10)
Número de intentos	Cuantitativa	Veces que el estudiante interactó con el juego	Númerica entera
Motivación	Cuantitativa	Valoración auto-reportada	Escala tipo Likert (1–5)

Mejora del aprendizaje	Cuantitativa	Diferencia calificación inicial	entre final e	Numérica continua
------------------------	--------------	---------------------------------------	------------------	-------------------

Nota: Describe el tipo de variable utilizada en la investigación (Autores, 2025).

Preparación de los Datos:

La preparación de los datos constituye una fase esencial dentro del proceso de análisis, ya que asegura la calidad, la consistencia y la pertinencia de la información destinada al modelado predictivo. Mediante procedimientos de limpieza, transformación e integración, se procura que los resultados obtenidos representen la realidad con fiabilidad y sirvan de apoyo para una toma de decisiones fundamentada en la cual se sigue el siguiente proceso:

1. En el desarrollo del estudio, la primera fase correspondió a la limpieza de los datos, donde se identificaron y eliminaron registros duplicados, además de corregirse errores de formato. Esta etapa fue decisiva para garantizar la coherencia de la información y su adecuada comparabilidad.
2. Después decidimos estandarizar todas las escalas que usamos para medir cosas como la motivación y usabilidad de los estudiantes y qué tan fácil les resultaba usar la plataforma. Era importante que todos estuviéramos midiendo lo mismo de la misma manera, porque así evitaríamos problemas más adelante cuando fuéramos a analizar los resultados.
3. Lo que hicimos después fue bastante interesante tomamos los datos que ya teníamos y los trabajamos para crear nuevas variables que nos dieran más información. Por ejemplo, combinamos varios indicadores para crear algo que llamamos (mejora en el aprendizaje matemático). La idea era tener una medida más completa que nos ayudara a predecir mejor los resultados de nuestro modelo.

La variable (mejora en el aprendizaje matemático) se calculó mediante la siguiente expresión:

$$Mejora (\%) = \frac{\text{Calificación final} - \text{Calificación inicial}}{\text{Calificación inicial}} \times 100$$

4. De manera paralela, las variables categóricas fueron codificadas mediante la técnica *one-hot encoding*, lo que permitió su conversión en variables *dummy* y su inclusión dentro de modelos de regresión, sin perder el carácter informativo de los registros originales.
5. Después de esto, juntamos toda la información de las diferentes fuentes que habíamos recopilado y la organizamos en una base de datos. Fue un trabajo minucioso, pero necesario para asegurar que todos los datos fueran coherentes entre sí y estuvieran bien estructurados en un solo lugar.
6. Una vez que tuvimos todo ordenado, preparamos los datos y los subimos a la plataforma que usaríamos para el análisis. De esta manera, quedaron

completamente listos para cuando llegáramos a la etapa de crear los modelos y hacer las predicciones que necesitábamos para nuestro estudio.

Modelado:

En esta etapa de la investigación se aplicaron técnicas de clasificación y análisis de series temporales (ver Tabla 2), con el propósito de examinar el aprendizaje desde una perspectiva predictiva, enfocada en el desempeño académico y en el seguimiento de su evolución a lo largo del tiempo.

Para determinar si los estudiantes lograron mejorar su aprendizaje, decidimos trabajar con dos enfoques complementarios: la Regresión logística y Random Forest. La primera nos resultó especialmente útil porque nos permite entender claramente qué factores están influyendo en los resultados y con qué probabilidad. Random Forest, por su parte, nos ayuda a captar esas relaciones más complejas que a veces no son tan evidentes a simple vista.

Organizando los datos dividiendo (70% para entrenar los modelos y reservando el 30% restante para las pruebas). También implementamos una validación cruzada con cinco grupos para asegurar que nuestros resultados fueran consistentes ajustando así los parámetros de cada modelo y probando hasta encontrar la configuración más optima.

Para observar la evolución de las calificaciones a lo largo del tiempo, utilizamos un modelo ARIMA con parámetros (1,1,1) trabajando con *Statsmodels*. Técnica que permitió identificar patrones temporales en el rendimiento académico y evaluar y predecir tendencias futuras. El escogimiento de estos parámetros específicos surgió del análisis detallado de los gráficos de autocorrelación y autocorrelación parcial, junto con la comparación de los criterios AIC y BIC. De esta manera, nos aseguramos de elegir la configuración del modelo que mejor se ajustara a nuestros datos.

Tabla 2
Configuración de los modelos predictivos

Modelo	Técnica	Algoritmo utilizado	División datos	Validación cruzada	Hiperparámetros principales
Clasificación	Regresión logística	LogisticRegression (Scikit-learn)	70% train / 30% test	k=5 folds	Solver = lbfgs, max_iter = 1000
Clasificación	Random Forest	RandomForestClassifier	70% / 30%	k=5 folds	n_estimators = 100, max_depth = None
Series temporales	ARIMA	ARIMA(p,d,q) (Statsmodels)	—	No aplica	p=1, d=1, q=1

Nota: Describe los modelos predictivos aplicados en la investigación (Autores, 2025).

Evaluación:

La verificación de los modelos de predicción se centró en averiguar su acierto y su utilidad a la hora de predecir el aprendizaje de los alumnos. Con este fin, se tuvieron en cuenta métricas conocidas como son: la exactitud (accuracy), la exhaustividad (recogida) y la medida F1 (F1-score), que permiten evaluar el comportamiento del modelo de regresión logística especialmente en escenarios con posible desbalanceo.

Se comparan las predicciones realizadas con las notas finales, lo que nos permite verificar qué tan cerca de la realidad están los valores que nos ofrecen los modelos.

Para asegurarme de que los resultados fueran realmente confiables, decidí optimizar los algoritmos usando validación cruzada k-fold y ajusté los hiperparámetros con búsqueda en cuadrícula. Esta combinación me ayudó a evitar el temido sobreajuste que tanto puede arruinar un modelo. A la hora de evaluar qué tan bien funcionaban los modelos, la matriz de confusión se convirtió en mi mejor aliada. Me permitió ver exactamente dónde se equivocaban las predicciones y elegir el modelo que mejor rendimiento ofrecía.

El análisis de series temporales, se utiliza las métricas clásicas como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el coeficiente de determinación (R^2). Las que dieron una imagen clara de qué tan precisas eran mis predicciones conforme pasaba el tiempo. Se incorporó bootstrapping como técnica de validación adicional, dando más confianza en los resultados afirmando que estos hallazgos podrían aplicarse sin problemas en otros contextos educativos similares.

A continuación, las fórmulas empleadas para evaluar el desempeño de los modelos de clasificación utilizados en el estudio:

$$\text{Accuracy} = \frac{(TP + TN)}{(TP + TN + FP + FN)}$$

$$\text{Recall} = \frac{TP}{(TP + FN)}$$

$$\text{Precision} = \frac{TP}{(TP + FP)}$$

$$F1(F1 - \text{score}) = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})}$$

Donde:

TP = Verdaderos Positivos

TN = Verdaderos Negativos

FP = Falsos Positivos

FN = Falsos Negativos

Despliegue:

Para certificar la sostenibilidad y la aplicabilidad futura de los modelos desarrollados, se diseña una estrategia de implementación en su integración operativa.

En la implementación técnica decidimos apostar por una arquitectura de microservicios desde el inicio, y fue una de nuestras mejores decisiones. Esto nos permitió crecer sin problemas y hacer ajustes sin que todo el sistema se tambaleara. Lo que realmente marcó la diferencia fue cómo organizamos al equipo: cada profesor,

técnico y administrativo sabía exactamente cuál era su parte en todo esto. Nada de confusiones ni responsabilidades difusas.

Para el control y adaptabilidad montamos un sistema de monitoreo que nos mantenía al tanto de todo en tiempo real. En educación no puedes darte el lujo de descubrir problemas días después. Pero lo que más nos enorgullece es cómo diseñamos la capacidad de aprendizaje continuo: los modelos se van ajustando solos a medida que aparecen nuevos datos y situaciones. Es como tener un sistema que evoluciona junto con los estudiantes y sus necesidades.

En los Resultados y proyección todo el proceso quedó documentado en un informe técnico que entregamos a la Unidad Educativa "Manuela Cañizares", pero no nos quedamos ahí. Lo compartimos con investigadores de otras instituciones porque creemos que, si algo funciona bien, debe poder replicarse y mejorarse en otros lugares. Al final, se trata de generar impacto más allá de un solo proyecto.

3. Resultados

Al iniciar el estudio sobre cómo un juego matemático inclusivo podría ayudar a jóvenes con necesidades especiales, nos encontramos con que nuestras sospechas se confirmaban: las matemáticas son una barrera importante en sus vidas. A la hora de recopilar datos de los niños, nos dimos cuenta de que casi dos tercios del grupo (65%) tienen dificultades con operaciones tan básicas como sumas y restas y el resto solo consigue un rendimiento medio al resolver problemas sencillos.

Y de ahí salía la siguiente distribución: casi la mitad de los estudiantes (48%) se encuentran en un nivel básico, poco más de un tercio (37%) rinden a un nivel medio, y solo unos pocos (15%) tienen habilidades más avanzadas, que veían mermadas por los niveles previos de su educación. El juego matemático aportó consigo una respuesta extraordinariamente positiva que superó nuestras expectativas.

El 85% de los estudiantes se sintió motivados durante las actividades, mientras que nueve de cada diez docentes destacaron lo accesible y práctica que resultaba la herramienta para sus clases diarias en la asignatura de matemáticas. Los usuarios calificaron la facilidad de uso con un promedio de 4.2 sobre 5 puntos, confirmando que habíamos logrado crear un aplicativo amigable y funcional para este grupo específico de estudiantes de necesidades especiales.

En el progreso académico a través de pruebas aplicadas antes y después de tres semanas de uso continuo del juego matemático. Los resultados iniciales mostraron que los estudiantes apenas lograban el 43.7% de respuestas correctas, ratificando las dificultades matemáticas existentes. Después de usar la herramienta durante ese tiempo, alcanzaron un 68,7% de aciertos, aumentando un 25% sus habilidades matemáticas.

Este aumento notable no solo da una lección de lo buenísimo que es el juego, sino que también validó completamente nuestra postura por combinar tecnología educativa con enfoques verdaderamente inclusivos, afirmando una esperanza sobre el potencial transformador de este tipo de innovaciones. En cuanto a las métricas de los modelos predictivos que se ven en la (Tabla 3), la regresión logística fue el modelo más preciso, con un 96% de aciertos, destacando también valores altos en recall (1.00) y F1-score (0.98).

El modelo Random Forest, fue menos preciso en un 88% y obtuvo valores también más bajos en F1-score 0.94, mientras que el análisis de series temporales con ARIMA dio una reducción del 25% en los errores de las matemáticas, lo que da una lección de que el camino seguido es el correcto.

Tabla 3
Resultados principales

Aspecto evaluado	Resultado principal
Dificultades iniciales	65% con problemas en operaciones básicas
Rendimiento inicial	Bajo: 48%, Medio: 37%, Alto: 15%
Motivación estudiantil	85% se sintió motivado
Opinión docente	90% destacó la accesibilidad del juego
Usabilidad	Promedio de 4.2/5
Mejora en habilidades matemáticas	Incremento del 25% tras tres semanas
Regresión Logística	Precisión: 96%, Recall: 1.00, F1-score: 0.98
Random Forest	Precisión: 88%, F1-score: 0.94
ARIMA (series temporales)	Reducción del 25% en errores matemáticos

Nota: Describe los resultados principales aplicados en la investigación (Autores, 2025).

3.1. Comparación de la efectividad de los modelos predictivos

Se llevó a cabo una comparación entre los modelos Random Forest y Regresión Logística con el objetivo de determinar cuál de ellos era más efectivo en la clasificación de los datos. Para ello, se evaluaron diferentes métricas de performance ampliamente utilizadas en el campo del aprendizaje automático. Entre ellas, se consideraron métricas como el accuracy, balanced accuracy, F1-score y ROC-AUC que permiten valorar tanto la precisión global del modelo como su performance en escenarios con clases potencialmente desbalanceadas.

Los hallazgos evidenciaron que el modelo de regresión logística alcanzó un desempeño superior en la mayoría de las métricas, con un nivel de exactitud del 96%, un F1-score de 0.98 y un ROC-AUC de 0.98. En contraste, el modelo Random Forest obtuvo un 88% de exactitud, un F1-score de 0.94 y un ROC-AUC de 0.93. Estos resultados reflejan que la regresión logística, además de ofrecer mayor interpretabilidad, constituye la alternativa más apropiada para la predicción del rendimiento académico dentro del presente estudio (véase Tabla 4).

Tabla 4
Desempeño de los modelos predictivos.

Modelo	Accuracy	Balanced Accuracy	F1-score	ROC-AUC	Interpretación
Random Forest	0.88	0.87	0.94	0.93	Buen desempeño, pero menor en comparación con la regresión logística.
Regresión Logística	0.96	0.95	0.98	0.98	Modelo con mayor efectividad y estabilidad predictiva.

Nota: Describe la comparación de efectividad de los modelos predictivos aplicados en la investigación (Autores, 2025).

4. Discusión

Los resultados alcanzados en esta investigación muestran que la implementación de un juego matemático inclusivo tuvo un efecto positivo en el aprendizaje de los estudiantes con necesidades especiales. Estos hallazgos coinciden con investigaciones previas que resaltan la utilidad de la gamificación en contextos educativos (Bang et al., 2022). El aumento del 25% en las destrezas matemáticas después de tres semanas de aplicación, junto con el alto nivel de motivación reportado por la mayoría de los estudiantes (85%) y la valoración positiva de los docentes en cuanto a la accesibilidad del recurso (90%), respaldan la idea de que las dinámicas lúdicas adaptadas pueden convertirse en una estrategia eficaz para fortalecer la participación y el compromiso en el proceso educativo (Cajamarca-Correa et al., 2024).

Sin embargo, al tratarse de una experiencia de corta duración, resulta necesario analizar si los beneficios identificados se mantienen en el tiempo. Al comparar los modelos predictivos, la Regresión logística presenta mejores resultados que Random Forest, algo que no esperábamos al principio. Reflexionando nos dimos cuenta de que nuestros datos y el tamaño de muestra se adaptaban mejor a un modelo más interpretable y menos propenso al sobreajuste. El modelo ARIMA también nos permitió dar seguimiento al rendimiento académico en el tiempo, reduciendo errores de predicción en un 25% comparado con métodos básicos.

Los resultados respaldan que el data análisis se puede confeccionar en un aliado importantísimo para tomar decisiones pedagógicas, sobre todo cuando estamos trabajando con estudiantes que tienen necesidades diversas. Diseñar actividades lúdicas inclusivas combinadas con técnicas predictivas puede ser la clave para conseguir una educación cada vez más equitativa. Creemos que sería interesante continuar la investigación con muestras más amplias y diversas; así podríamos entender mejor si nuestra propuesta es útil en diferentes entornos educativos y si podemos confiar en ella en otras aulas (Torres-Roberto, 2024).

5. Conclusiones

Los números nos golpearon fuerte al descubrir que el 65% de nuestros estudiantes batallaba con matemáticas básicas, pero esa preocupación se transformó en esperanza cuando vimos los resultados del juego inclusivo que desarrollamos. Lo que más nos emocionó fue observar cómo el 85% de los chicos disfrutó genuinamente la experiencia mientras los profesores elogiaban la facilidad de uso de la herramienta. Nuestros modelos predictivos alcanzaron una precisión del 96%, con la regresión logística destacándose por su exactitud (solo 3.5% de error), y documentamos una mejora del 25% en habilidades matemáticas tras apenas tres semanas de implementación, confirmando que la tecnología puede ser una aliada poderosa para hacer la educación más inclusiva y efectiva.

Este artículo muestra que un 65% de alumnos con dificultades en las operaciones básicas de matemáticas es todo un desafío educativo que requiere de nuevas formas de afrontar la enseñanza. La puesta en marcha del juego matemático inclusivo ha sido una estrategia pedagógica eficaz en un 85% de los casos y muy bien acogida entre el profesorado por su sencillez, mientras que el uso de heurísticas para el análisis de la usabilidad ha confirmado la capacidad que tiene la herramienta de ser interactiva y adaptable. Los modelos de predicción, en especial el de regresión logística, han sido capaces de alcanzar hasta el 96% de precisión con un 3,5% de desviación, de mejorar el rendimiento de los alumnos en un 25%, tras tres semanas de trabajo, y por lo tanto de dar la razón a la apuesta que las TIC y la IA deberían jugar en las metodologías inclusivas de la docencia-aprendizaje.

Nuestros resultados son claros y contundentes frente al 65% de estudiantes con dificultades en matemáticas básicas, el juego matemático inclusivo se mostró como una solución efectiva con 85% de satisfacción estudiantil y alta adopción docente. Los modelos predictivos de inteligencia artificial, especialmente la regresión logística, demostraron 96% de precisión con apenas 3.5% de desviación entre predicciones y resultados reales, mientras documentamos una mejora tangible del 25% en habilidades matemáticas tras solo tres semanas de aplicación confirmando así que al combinar pedagogía inclusiva y tecnología inteligente produce resultados medibles y significativos que justifican la escalabilidad de esta propuesta educativa.

Identificando la realidad del 65% de estudiantes luchando con matemáticas básicas se convirtió en una historia de éxito que redefine las posibilidades educativas del siglo XXI. El juego matemático inclusivo no solo captó la atención del 85% de participantes y conquistó a los docentes por su accesibilidad, sino que demostró el poder transformador de la tecnología en educación. Con modelos predictivos que alcanzaron 96% de precisión, especialmente la regresión logística con solo 3.5% de error, y una mejora documentada del 25% en habilidades matemáticas en tres semanas, hemos demostrado que la educación inclusiva potenciada con tecnología es una realidad presente que puede revolucionar cómo enseñamos, aprendemos y transformamos vidas a través del conocimiento.

CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.

Referencias Bibliográficas

- Arcila Calderón, C., Ortega Mohedano, F., Álvarez, M., & Vicente Mariño, M. (2019). Análisis distribuido y supervisado de sentimientos en Twitter: Integrando aprendizaje automático y analítica en tiempo real para retos de dimensión big data en investigación de comunicación y audiencias. *Empiria. Revista de metodología de ciencias sociales*, (42), 113–136. <https://doi.org/10.5944/empiria.42.2019.23254>
- Baker, R. S., & Yacef, K. (2009). The state of educational data mining in 2009: A review and future visions. *Journal of Educational Data Mining*, 1(1), 3–17. <https://jedm.educationaldatamining.org>
- Bang, M., Vongkulluksn, V. W., Xie, K., & Hu, X. (2022). Gamification and mathematics learning: A meta-analysis on the impact of digital games in K-12 education. *Educational Technology Research and Development*, 70(3), 837–861. <https://doi.org/10.1007/s11423-021-10017-4>
- Cajamarca-Correa, M. A., Cangas-Cadena, A. L., Sánchez-Simbaña, S. E., & Pérez-Guillermo, A. G. (2024). Nuevas tendencias en el uso de recursos y herramientas de la Tecnología Educativa para la Educación Universitaria. *Journal of Economic and Social Science Research*, 4(3), 127–150. <https://doi.org/10.55813/gaea/jessr/v4/n3/124>
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc. <https://www.kde.cs.uni-kassel.de/lehre/ws2012-13/kdd/files/CRISPWP-0800.pdf>
- Concha-Ramirez, J. A., Saavedra-Calberto, I. M., Ordoñez-Loor, I. I., & Alcivar-Córdova, D. M. (2023). Impacto de la gamificación en la motivación y el compromiso estudiantil en educación primaria. *Revista Científica Ciencia Y Método*, 1(4), 44–55. <https://doi.org/10.55813/gaea/rcym/v1/n4/22>
- Del Campo, M., López, M., & Sanabria, A. (2017). Estrategias para la enseñanza inclusiva de las matemáticas: Un enfoque constructivista. *Revista de Educación Inclusiva*, 10(2), 45–63. <https://revistaeducacioninclusiva.com>
- Durairaj, M., & Vijitha, S. (2014). Educational Data Mining for Prediction of Student Performance Using Clustering Algorithms. *International Journal of Computer Applications*, 99(3), 1–7. <https://doi.org/10.5120/17418-7823>
- García, E., Sánchez, J., & Ríos, F. (2021). Análisis de series temporales en la educación: Evaluación del aprendizaje basado en juegos. *Revista Internacional de Tecnología Educativa*, 13(1), 112–130. <https://doi.org/10.1016/j.rtedu.2021.05.009>
- Michuy-Guingla, T. E., Fajardo-Andrade, C. A., Fajardo-Andrade, M. F., Limongi-Basantes, D. S., & Quiroz-Parraga, F. A. (2025). La tecnología educativa en el

- proceso de aprendizaje de estudiantes con necesidades educativas específicas. *Revista Científica Ciencia Y Método*, 3(3), 42-58. <https://doi.org/10.55813/gaea/rcym/v3/n3/59>
- Moreno, R., Torres, J., & Pérez, M. (2020). La relación entre motivación y aprendizaje en estudiantes con necesidades educativas especiales. *Revista Latinoamericana de Psicología Educativa*, 9(2), 67-89. <https://doi.org/10.1016/j.psicoedu.2020.07.005>
- Piaget, J. (2013). *Play, dreams and imitation in childhood*. Norton. <https://doi.org/10.4324/9781315009698>
- Ramani, G. B., Purpura, D. J., & Cirino, P. T. (2020). The Role of Play in Mathematics Learning for Young Children. *Journal of Numerical Cognition*, 6(2), 123-140. <https://doi.org/10.5964/jnc.v6i2.437>
- Rodríguez-García, A., & Arias-Gago, A. R. (2022). Modelos didácticos en matemáticas y su relación con el aprendizaje significativo. *Profesorado. Revista de Currículum y Formación del Profesorado*. <https://revistaseug.ugr.es/index.php/profesorado>
- Screpnik, C.R., Cabrera, J., Negre, F. y Salinas, J. (2023). Videojuegos aplicados a la enseñanza de las matemáticas iniciales: una revisión sistemática. *RiiTE Revista interuniversitaria de investigación en tecnología educativa*, 1579-102. <https://doi.org/10.6018/riite.558751>
- Torres-Roberto, M. A. (2024). Evaluación Formativa Continua en la Enseñanza y aprendizaje del Cálculo: Mejorando el Rendimiento Académico en Estudiantes de Educación Profesional. *Journal of Economic and Social Science Research*, 4(2), 93–113. <https://doi.org/10.55813/gaea/jessr/v4/n2/104>
- Velastegui, R. (2023). Aplicación de algoritmos de aprendizaje automático en la evaluación educativa. *Dirección y Organización*, 80, 6-17. <https://dialnet.unirioja.es>
- Zambrano, C. B. (2025). Gamification as a didactic strategy for teaching Mathematics in elementary education. *Journal of Advances in Education, Sciences and Humanities*, 3(1), 21-32. <https://doi.org/10.5281/zenodo.14816610>