

**ANALÍTICA PREDICTIVA Y APRENDIZAJE PERSONALIZADO EN ESTUDIANTES DE
SISTEMAS, GUAYAQUIL, 2025**
**PREDICTIVE ANALYTICS AND PERSONALIZED LEARNING IN SYSTEMS STUDENTS,
GUAYAQUIL, 2025**

Autores: ¹**Eudes Leonidas Banchón Bohórquez, ²Kevin Alejandro Aveiga Rodríguez, ³Miguel Ángel Arce Calvache y ⁴Milton Alfonso Criollo Turusina.**

¹ORCID ID: <https://orcid.org/0009-0007-3658-6049>

²ORCID ID: <https://orcid.org/0009-0001-7089-6557>

³ORCID ID: <https://orcid.org/0009-0003-7896-1610>

⁴ORCID ID: <https://orcid.org/0000-0002-3394-1160>

¹E-mail de contacto: ebanchonb2@unemi.edu.ec

²E-mail de contacto: kaveigar@unemi.edu.ec

³E-mail de contacto: marcec3@unemi.edu.ec

⁴E-mail de contacto: mcriollot2@unemi.edu.ec

Afilación: ^{1*2*3*4*}Universidad Estatal de Milagro, (Ecuador).

Artículo recibido: 25 de Enero de 2026

Artículo revisado: 27 de Enero del 2026

Artículo aprobado: 3 de Febrero del 2026

¹Ingeniero en Sistemas Computacionales, egresado de la Universidad de Guayaquil, (Ecuador), con más de 10 años de experiencia en el área de desarrollo de software. Maestrante de la Maestría en Educación, con mención en Docencia e Investigación en Educación Superior, en la Universidad Estatal de Milagro, (Ecuador).

²Ingeniero Industrial, egresado de la Universidad Técnica Estatal de Quevedo, (Ecuador), con más de 3 años de experiencia en docencia. Maestrante de la Maestría en Educación, con mención en Docencia e Investigación en Educación Superior, en la Universidad Estatal de Milagro, (Ecuador).

³Ingeniero Agrónomo, egresado de la Universidad Agraria del Ecuador, (Ecuador), con más de 5 años de experiencia en el área comercial como representante técnico comercial y administrador. Maestrante de la Maestría en Educación, con mención en Docencia e Investigación en Educación Superior, en la Universidad Estatal de Milagro, (Ecuador).

⁴Licenciado en Ciencias de la Educación especialización en Arte, graduado de la Universidad de Guayaquil, (Ecuador). Maestro en Docencia Universitaria graduado de la Universidad Cesar Vallejo (Perú). Doctorante en Educación en la Universidad César Vallejo, (Perú).

Resumen

El objetivo del estudio fue determinar la relación entre la analítica predictiva y el aprendizaje personalizado en estudiantes de la carrera de Ingeniería de Sistemas de una universidad pública de Guayaquil, considerando como alcance el análisis de la asociación entre ambas variables y sus dimensiones. La investigación se desarrolló bajo un enfoque cuantitativo, de tipo básico y alcance correlacional-asociativo, con diseño no experimental y corte transversal. Se aplicó una encuesta estructurada mediante un cuestionario tipo Likert de veintisiete ítems a una muestra probabilística de ciento cincuenta y dos estudiantes. El instrumento presentó adecuados niveles de confiabilidad y los datos fueron analizados mediante estadística inferencial utilizando el coeficiente de correlación de Pearson. Los resultados evidenciaron relaciones positivas y estadísticamente significativas entre las

dimensiones de la analítica predictiva y el aprendizaje personalizado. La utilidad del análisis de grandes volúmenes de datos mostró una correlación positiva baja, mientras que la satisfacción con herramientas digitales y la retroalimentación inmediata presentaron correlaciones positivas moderadas. Asimismo, se identificó una correlación positiva moderada entre la analítica predictiva en conjunto y el aprendizaje personalizado. Se concluye que un mayor nivel de implementación de estrategias de analítica predictiva se asocia con mayores niveles de aprendizaje personalizado en el contexto universitario analizado, lo que resalta su relevancia como apoyo para la toma de decisiones pedagógicas orientadas a atender las necesidades individuales de los estudiantes.

Palabras clave: **Analítica predictiva, Aprendizaje personalizado, Educación Superior, Análisis correlacional, Big Data educativo, Herramientas digitales, Retroalimentación inmediata, Rendimiento académico.**

Abstract

The objective of the study was to determine the relationship between predictive analytics and personalized learning in students studying Systems Engineering at a public university in Guayaquil, considering the scope of the analysis of the association between both variables and their dimensions. The research was carried out using a quantitative approach, of a basic nature and correlational-associative scope, with a non-experimental and cross-sectional design. A structured survey using a 27-item Likert-type questionnaire was administered to a probabilistic sample of 152 students. The instrument presented adequate levels of reliability, and the data were analyzed using inferential statistics and Pearson's correlation coefficient. The results showed positive and statistically significant relationships between the dimensions of predictive analytics and personalized learning. The usefulness of big data analysis showed a low positive correlation, while satisfaction with digital tools and immediate feedback showed moderate positive correlations. Likewise, a moderate positive correlation was identified between predictive analytics as a whole and personalized learning. It is concluded that a higher level of implementation of predictive analytics strategies is associated with higher levels of personalized learning in the university context analyzed, highlighting its relevance as a support for pedagogical decision-making aimed at meeting the individual needs of students.

Keywords: **Predictive analytics, Personalized learning, Higher Education, Correlational analysis, Educational Big Data, Digital tools, Immediate feedback, Academic performance.**

Sumário

O objetivo do estudo foi determinar a relação entre a análise preditiva e a aprendizagem personalizada em estudantes do curso de Engenharia de Sistemas de uma universidade pública de Guayaquil, considerando como escopo a análise da associação entre ambas as variáveis e suas dimensões. A investigação foi

desenvolvida sob uma abordagem quantitativa, de tipo básico e alcance correlacional-associativo, com desenho não experimental e transversal. Foi aplicado um inquérito estruturado por meio de um questionário do tipo Likert com 27 itens a uma amostra probabilística de 152 estudantes. O instrumento apresentou níveis adequados de confiabilidade e os dados foram analisados por meio de estatística inferencial utilizando o coeficiente de correlação de Pearson. Os resultados evidenciaram relações positivas e estatisticamente significativas entre as dimensões da análise preditiva e a aprendizagem personalizada. A utilidade da análise de grandes volumes de dados mostrou uma correlação positiva baixa, enquanto a satisfação com ferramentas digitais e o feedback imediato apresentaram correlações positivas moderadas. Da mesma forma, foi identificada uma correlação positiva moderada entre a análise preditiva em conjunto e a aprendizagem personalizada. Conclui-se que um maior nível de implementação de estratégias de análise preditiva está associado a maiores níveis de aprendizagem personalizada no contexto universitário analisado, o que destaca a sua relevância como apoio à tomada de decisões pedagógicas orientadas para atender às necessidades individuais dos estudantes.

Palavras-Chave: **Análise preditiva, Aprendizagem personalizada, Ensino Superior, Análise correlacional, Big Data Educacional, Ferramentas digitais, Feedback imediato, Desempenho académico.**

Introducción

En el contexto internacional, la educación superior atraviesa un proceso acelerado de transformación digital impulsado por el uso de analítica predictiva, Big Data e inteligencia artificial, con el propósito de mejorar la toma de decisiones pedagógicas y fortalecer el aprendizaje personalizado. Diversos estudios empíricos realizados en distintos países evidencian el impacto positivo de estas tecnologías en el rendimiento académico y la adaptación de los procesos educativos a las

necesidades de los estudiantes. En España, García et al. (2022) desarrollaron el estudio “Learning analytics and personalized learning pathways in higher education”, con el objetivo de analizar el efecto de la analítica predictiva en la personalización del aprendizaje universitario. Con un enfoque cuantitativo y diseño predictivo, estudiaron a 3,200 estudiantes de universidades públicas, evidenciando una mejora del 15 % en el rendimiento académico y una reducción del 12 % en la deserción, confirmando que la analítica predictiva permite adaptar los procesos formativos a las necesidades individuales del estudiante.

En Estados Unidos, Matz et al. (2023) desarrollaron el estudio “Using machine learning to predict student retention from socio-behavioral and institutional data”, cuyo objetivo fue identificar estudiantes universitarios en riesgo de abandono académico mediante analítica predictiva. Con un enfoque cuantitativo y diseño predictivo, analizaron datos socioacadémicos de 8,000 estudiantes universitarios utilizando algoritmos de aprendizaje automático, alcanzando una precisión del 78 % en la predicción de la retención estudiantil, lo que evidencia que la analítica predictiva permite anticipar conductas de deserción y orientar estrategias de aprendizaje personalizado basadas en el perfil del estudiante. Asimismo, en Estados Unidos, Liu et al. (2021) desarrollaron el estudio “Early prediction of student performance using learning analytics in higher education”, cuyo propósito fue evaluar la efectividad de modelos predictivos para anticipar el rendimiento académico. Mediante un enfoque cuantitativo y diseño no experimental predictivo, analizaron datos académicos y de interacción en plataformas virtuales de 4,500 estudiantes universitarios, obteniendo una precisión predictiva del 75 %, lo que permitió

implementar intervenciones tempranas y personalizadas, evidenciando el aporte de la analítica predictiva al aprendizaje personalizado.

En México, Reyes et al. (2024) realizaron el estudio “Predictive analytics as a tool to enhance personalized learning in higher education”, con el propósito de evaluar la efectividad de la analítica predictiva en el aprendizaje personalizado. A través de un enfoque cuantitativo y diseño no experimental predictivo, analizaron datos académicos y de interacción virtual de 1,500 estudiantes universitarios, evidenciando una mejora del 18 % en el rendimiento académico y una reducción del 10 % en la reprobación, concluyendo que la analítica predictiva constituye una herramienta clave para personalizar el aprendizaje en la educación superior. A nivel regional, particularmente en América Latina, la adopción de la analítica predictiva y el aprendizaje personalizado presenta avances desiguales. Si bien diversas instituciones de educación superior cuentan con plataformas digitales y sistemas de información académica, su uso con fines predictivos y adaptativos aún no se encuentra plenamente consolidado.

En Colombia, Ortega et al. (2022) desarrollaron el estudio “Learning analytics and predictive models for academic performance in higher education”, cuyo objetivo fue analizar la efectividad de la analítica predictiva para identificar estudiantes en riesgo académico. Con un enfoque cuantitativo y diseño no experimental predictivo, analizaron datos académicos y de interacción virtual de 2,100 estudiantes universitarios, obteniendo una precisión del 73 % en la predicción del bajo rendimiento, lo que permitió implementar intervenciones pedagógicas diferenciadas, evidenciando que la analítica predictiva contribuye a fortalecer el aprendizaje

personalizado en la educación superior. En Perú, Velasco et al. (2023) realizaron el estudio “Predictive analytics and personalized learning in university students”, con el propósito de evaluar el impacto de la analítica predictiva en el aprendizaje personalizado. Bajo un enfoque cuantitativo y diseño predictivo, analizaron datos académicos de 1,200 estudiantes universitarios, evidenciando una mejora del 14 % en el rendimiento académico tras la aplicación de estrategias personalizadas basadas en modelos predictivos, concluyendo que el uso de datos educativos favorece la adaptación de los procesos formativos a las necesidades individuales del estudiante.

En Brasil, et al. (2021) desarrollaron el estudio “Educational data mining and predictive analytics to support personalized learning”, cuyo objetivo fue analizar el uso de modelos predictivos para mejorar el rendimiento académico. Con un enfoque cuantitativo y diseño no experimental predictivo, estudiaron a 3,500 estudiantes universitarios, obteniendo una mejora del 16 % en el desempeño académico promedio, lo que evidenció que la analítica predictiva permite personalizar contenidos y ritmos de aprendizaje, optimizando la toma de decisiones pedagógicas en la educación superior. En Argentina, Vargas et al. (2022) realizaron el estudio “Predictive learning analytics and academic performance in higher education”, con el propósito de evaluar la relación entre analítica predictiva y aprendizaje personalizado. Mediante un enfoque cuantitativo y diseño predictivo, analizaron datos académicos de 1,800 estudiantes universitarios, identificando una reducción del 13 % en los índices de reprobación, lo que permitió ajustar estrategias pedagógicas al perfil del estudiante y fortalecer los procesos de aprendizaje personalizado.

En la carrera de Ingeniería de Sistemas de la Universidad de Guayaquil se generan grandes volúmenes de datos académicos provenientes de plataformas virtuales, evaluaciones y registros institucionales; no obstante, su uso mediante analítica predictiva para apoyar el aprendizaje personalizado sigue siendo limitado. Esta situación dificulta la detección temprana de dificultades académicas y la adecuación de los procesos de enseñanza-aprendizaje a las necesidades individuales. Considerando la abundante información digital que producen estas carreras y sus elevadas tasas de deserción, la analítica predictiva representa una oportunidad estratégica para mejorar el rendimiento, la permanencia estudiantil y la calidad educativa, al permitir intervenciones pedagógicas más precisas, equitativas y orientadas a la formación de profesionales autónomos. La transformación digital en la educación superior ha impulsado la incorporación de tecnologías basadas en datos con el propósito de optimizar los procesos de enseñanza y aprendizaje. En este contexto, la analítica predictiva ha emergido como una herramienta clave al permitir el uso de modelos estadísticos, algoritmos de aprendizaje automático y análisis de grandes volúmenes de datos para anticipar comportamientos y resultados académicos, facilitando la toma de decisiones pedagógicas basadas en evidencia (Sajja et al., 2023). Su aplicación en entornos educativos no solo fortalece la gestión académica, sino que también abre posibilidades para diseñar intervenciones personalizadas orientadas a mejorar el rendimiento y la permanencia estudiantil.

A nivel teórico, la analítica predictiva educativa se sustenta en modelos que integran inteligencia artificial, Big Data y analítica del aprendizaje para respaldar decisiones pedagógicas basadas en datos y estrategias de intervención

personalizadas. Entre sus principales dimensiones se encuentran la utilidad del Big Data, relacionada con el análisis de grandes volúmenes de información para predecir comportamientos académicos; la satisfacción con herramientas digitales, vinculada con la percepción de utilidad y facilidad de uso de plataformas tecnológicas (Rogers, 2003); y la retroalimentación inmediata, entendida como el uso de información en tiempo real para ajustar las estrategias de enseñanza (Sajja et al., 2023). Estas dimensiones permiten operacionalizar la analítica predictiva de manera empírica y medible dentro de contextos educativos mediados por tecnología. El sustento conceptual de esta variable se refuerza con la Teoría de la Analítica Predictiva, que destaca la capacidad de los modelos basados en inteligencia artificial para anticipar patrones de rendimiento y prevenir la deserción estudiantil (Bellomo, 2023). Asimismo, la Teoría del Conocimiento Organizacional resalta que el uso de datos transforma el conocimiento tácito en explícito, fortaleciendo la toma de decisiones institucionales (Gándara y Anahideh, 2025). Desde la perspectiva de la innovación, la adopción de la analítica predictiva en educación se relaciona con factores como la ventaja relativa y la facilidad de uso, elementos clave en la difusión de innovaciones tecnológicas (Mazhar, 2025).

Paralelamente, el aprendizaje personalizado se concibe como un enfoque que adapta contenidos, estrategias y ritmos de enseñanza a las características individuales de los estudiantes, promoviendo su autonomía y mejora del rendimiento académico (Reyes Parra et al., 2024; Velasco et al., 2023; Rivera-Arzola, 2021). Su modelo teórico se apoya en propuestas basadas en inteligencia artificial y machine learning que consideran dimensiones como el comportamiento de aprendizaje, los

estilos de aprendizaje y la ruta de aprendizaje individualizada, elementos que permiten estructurar experiencias formativas adaptativas (De la Rosa, 2024). Las bases teóricas del aprendizaje personalizado se articulan con el constructivismo digital, que reconoce el papel de los entornos tecnológicos en la construcción activa del conocimiento (Kivunja, 2023; Reigeluth y Beatty, 2022); la teoría del aprendizaje autorregulado, que enfatiza la autonomía y el control metacognitivo del estudiante (Panadero, 2022); y la teoría del aprendizaje cognitivo multimedia, que explica la integración de estímulos visuales y verbales para favorecer aprendizajes significativos en entornos digitales (Mayer, 2023).

Desde el punto de vista social, el estudio de la relación entre analítica predictiva y aprendizaje personalizado resulta relevante ante la necesidad de transformar los entornos educativos mediante tecnologías emergentes que respondan a una sociedad cada vez más digitalizada. En ciudades como Guayaquil, las brechas en el acceso a recursos educativos y la falta de estrategias adaptativas influyen en el rendimiento académico, por lo que la ciencia aplicada a la educación puede contribuir a reducir desigualdades mediante soluciones contextualizadas (Ortega, 2023). En el ámbito pedagógico, la integración de datos para anticipar necesidades formativas permite rediseñar prácticas docentes hacia modelos más flexibles y centrados en el estudiante (Méndez, 2022). A nivel práctico, la analítica educativa facilita la toma de decisiones académicas basadas en algoritmos predictivos, transformando los datos en acciones efectivas (Vargas, 2024). Asimismo, la pertinencia del estudio se vincula con las tendencias globales de educación inteligente y con la modernización curricular en instituciones de educación superior (Rivas, 2023).

Materiales y Métodos

La investigación fue de tipo básica, con enfoque cuantitativo y diseño no experimental de corte transversal, orientada a analizar la relación entre la analítica predictiva y el aprendizaje personalizado en el contexto de la educación superior. El alcance del estudio fue correlacional-asociativo, ya que se buscó determinar el grado de asociación entre las variables sin establecer relaciones de causalidad, observando los fenómenos en su entorno natural. La población estuvo conformada por 250 estudiantes de la carrera de Ingeniería de Sistemas de una universidad de Guayaquil, matriculados y activos durante el período académico 2025. La muestra fue probabilística y se determinó mediante la fórmula para poblaciones finitas, con un nivel de confianza del 95 % y un margen de error del 5 %, obteniéndose un total de 152 estudiantes. Se empleó un muestreo probabilístico aleatorio simple, garantizando que todos los miembros de la población tuvieran la misma probabilidad de ser seleccionados. Como criterio de inclusión se consideró a estudiantes activos que utilizaran plataformas digitales institucionales, mientras que se excluyó a quienes no aceptaron participar voluntariamente en el estudio.

La técnica de recolección de datos fue la encuesta, aplicada mediante un cuestionario estructurado tipo Likert de 27 ítems, distribuidos en dos variables: analítica predictiva (15 ítems) y aprendizaje personalizado (12 ítems). El instrumento fue elaborado con base en modelos teóricos validados y presentó adecuados niveles de confiabilidad, con coeficientes alfa de Cronbach superiores a 0.80 para ambas variables. Los datos recolectados fueron organizados, depurados y codificados en una matriz de datos, para posteriormente ser procesados mediante el software estadístico

IBM SPSS Statistics (versión 30). Con el fin de contrastar las hipótesis planteadas, se aplicaron técnicas de estadística inferencial orientadas al análisis de la relación entre las variables analítica predictiva y aprendizaje personalizado.

Previo a la aplicación de los análisis inferenciales, se evaluó la confiabilidad del instrumento de recolección de datos mediante el coeficiente alfa de Cronbach, con el propósito de verificar la consistencia interna de los ítems que conforman cada variable y el cuestionario en su conjunto. Se consideraron valores iguales o superiores a 0.70 como indicadores de adecuada confiabilidad. Posteriormente, se empleó el coeficiente de correlación de Pearson (r) para determinar la intensidad y dirección de la relación entre la analítica predictiva y el aprendizaje personalizado. El análisis se realizó considerando un nivel de significancia estadística de $p < 0.05$, lo que permitió establecer asociaciones estadísticamente significativas entre las variables, en coherencia con el alcance correlacional-asociativo del estudio y sin pretender establecer relaciones de causalidad. En cuanto a los aspectos éticos, la investigación respetó la participación voluntaria de los estudiantes mediante consentimiento informado, garantizando la confidencialidad, el anonimato y el uso académico de la información recopilada, conforme a la normativa vigente de protección de datos personales.

Resultados y Discusión

Tabla 1. Correlación entre la utilidad del Big Data y el aprendizaje personalizado

Variables	r	p	n
Utilidad del Big Data – Aprendizaje personalizado	0.322	< 0.001	152

Fuente: Elaboración propia

El coeficiente de correlación obtenido indica la existencia de una asociación positiva entre la utilidad del Big Data y el aprendizaje personalizado, con un nivel de significancia estadística inferior a 0.05. El valor de $r = 0.322$ corresponde a una correlación positiva de magnitud baja a moderada, lo que sugiere que mayores niveles de aprovechamiento del Big Data tienden a asociarse con mayores niveles de aprendizaje personalizado. Los resultados obtenidos evidencian una correlación positiva y estadísticamente significativa entre la utilidad del Big Data y el aprendizaje personalizado. Este hallazgo sugiere que el aprovechamiento de grandes volúmenes de datos educativos se asocia con mayores niveles de personalización del aprendizaje, sin que ello implique necesariamente una relación causal directa entre ambas variables. Estos resultados son consistentes con los planteamientos de Siemens y Baker (2012), quienes sostienen que el análisis de datos educativos permite identificar patrones de comportamiento y desempeño académico relevantes para la toma de decisiones pedagógicas. De manera similar, Romero y Ventura (2020) destacan que la analítica del aprendizaje facilita la adaptación de los procesos formativos a las características individuales de los estudiantes, fortaleciendo así el aprendizaje personalizado.

Asimismo, Ferguson (2019) señala que el valor del Big Data en educación radica en su capacidad para apoyar decisiones basadas en evidencia, especialmente cuando se orienta a mejorar la experiencia de aprendizaje. En este sentido, la correlación observada respalda la idea de que el uso estratégico de datos contribuye a la personalización, aunque su impacto depende del contexto institucional y del nivel de integración pedagógica. Por su parte, Kim et al. (2018) indican que los sistemas de analítica educativa permiten generar

información relevante para la adaptación de contenidos y actividades, lo que favorece trayectorias de aprendizaje más flexibles. Esto explica que la relación observada sea significativa, pero de magnitud moderada, dado que la personalización del aprendizaje depende también de otros factores pedagógicos y tecnológicos. Desde una perspectiva metodológica, estos resultados confirman la pertinencia del enfoque correlacional adoptado en el estudio, al evidenciar una asociación significativa entre las variables analizadas. En consecuencia, la utilidad del Big Data se consolida como un componente relevante dentro de los modelos de aprendizaje personalizado en educación superior.

Tabla 2. Correlación entre la satisfacción del uso de herramientas digitales y el aprendizaje personalizado

Variables	r	p	n
Satisfacción con herramientas digitales – Aprendizaje personalizado	0.476	< 0.001	152

Fuente: Elaboración propia

El análisis correlacional evidencia una asociación positiva estadísticamente significativa entre la satisfacción con el uso de herramientas digitales y el aprendizaje personalizado. El coeficiente $r = 0.476$ indica una correlación positiva de magnitud moderada, lo que refleja que niveles más altos de satisfacción con las herramientas digitales se asocian con mayores niveles de personalización del aprendizaje. Los resultados presentados muestran una correlación positiva y estadísticamente significativa entre la satisfacción con el uso de herramientas digitales y el aprendizaje personalizado. Este hallazgo indica que los estudiantes que perciben de manera favorable las plataformas tecnológicas tienden a experimentar mayores niveles de personalización en su proceso de aprendizaje.

Este resultado coincide con lo propuesto por Davis (1989), quien señala que la percepción de utilidad y facilidad de uso de una tecnología influye directamente en su aceptación. En el ámbito educativo, esta aceptación se traduce en un mayor uso de herramientas digitales que permiten adaptar contenidos, actividades y ritmos de aprendizaje a las necesidades del estudiante. De igual forma, Venkatesh et al. (2012) amplían este planteamiento al afirmar que la satisfacción con la tecnología condiciona su uso efectivo y sostenido. En este contexto, la correlación observada sugiere que la satisfacción tecnológica facilita la implementación de estrategias de aprendizaje personalizado mediadas por plataformas digitales. Asimismo, García et al. (2021) destacan que las plataformas digitales bien valoradas por los estudiantes favorecen el diseño de trayectorias de aprendizaje adaptativas. En concordancia, Khalil y Ebner (2017) señalan que la interacción activa con sistemas digitales permite recopilar datos relevantes que fortalecen la personalización del aprendizaje. Esto confirma la relevancia de considerar la percepción estudiantil como un componente clave en estudios sobre analítica educativa.

Tabla 3. Correlación entre la retroalimentación inmediata y el aprendizaje personalizado

Variables	r	p	n
Retroalimentación inmediata – Aprendizaje personalizado	0.423	< 0.001	152

Fuente: Elaboración propia

Los resultados muestran una relación positiva y estadísticamente significativa entre la retroalimentación inmediata y el aprendizaje personalizado. El valor $r = 0.423$ corresponde a una correlación positiva de magnitud moderada, lo que indica que la retroalimentación oportuna

se asocia con mayores niveles de personalización del aprendizaje. Los resultados evidencian una correlación positiva y estadísticamente significativa entre la retroalimentación inmediata y el aprendizaje personalizado. Este hallazgo sugiere que la provisión oportuna de información sobre el desempeño académico se asocia con mayores niveles de adaptación del proceso de aprendizaje a las necesidades individuales de los estudiantes. La literatura respalda estos resultados, ya que Hattie y Timperley (2007) señalan que la retroalimentación constituye uno de los factores con mayor influencia en el aprendizaje, especialmente cuando se proporciona de forma inmediata y orientada a la mejora. En este sentido, la retroalimentación permite a los estudiantes comprender sus avances y dificultades, favoreciendo ajustes oportunos en sus estrategias de aprendizaje.

De manera complementaria, Shute (2008) destaca que la retroalimentación inmediata promueve procesos de autorregulación, al facilitar que los estudiantes monitorean su propio desempeño y tomen decisiones informadas sobre su aprendizaje. La correlación observada refuerza esta perspectiva, al evidenciar la relación entre la retroalimentación y la personalización del aprendizaje en contextos universitarios. En entornos digitales, Nicol y Macfarlane (2006) sostienen que la retroalimentación automatizada contribuye a experiencias de aprendizaje más flexibles y centradas en el estudiante. Asimismo, Pardo et al. (2019) señalan que los sistemas de analítica educativa permiten generar retroalimentación en tiempo real, fortaleciendo la capacidad de adaptación de los procesos formativos a las características individuales del alumnado. En conjunto, estos resultados resaltan la relevancia de la retroalimentación inmediata como un componente clave del aprendizaje

personalizado, especialmente en contextos de educación superior mediados por tecnología. El estudio aporta evidencia empírica que refuerza la necesidad de integrar mecanismos de retroalimentación oportuna dentro de los entornos virtuales de aprendizaje, no solo como un recurso informativo, sino como una estrategia pedagógica fundamental para atender la diversidad de ritmos y estilos de aprendizaje.

Tabla 4. Correlación entre analítica predictiva y aprendizaje personalizado

Variables	r	p	n
Analítica predictiva – Aprendizaje personalizado	0.41	< 0.05	152

Fuente: Elaboración propia

El coeficiente de correlación evidencia una relación positiva moderada entre ambas variables, lo que indica que el incremento en el uso de analítica predictiva se asocia con mayores niveles de aprendizaje personalizado. Los resultados presentados en la evidencian una correlación positiva moderada y estadísticamente significativa entre la analítica predictiva y el aprendizaje personalizado en el contexto de la educación superior ($r = 0.41$; $p < 0.05$; $n = 152$), lo que permite aceptar la hipótesis planteada, al confirmarse la existencia de una asociación significativa entre ambas variables dentro del marco del estudio. Desde el punto de vista metodológico, el valor del coeficiente de correlación indica una relación de magnitud relevante para un análisis de alcance correlacional, mientras que el nivel de significancia estadística obtenido demuestra que la probabilidad de que la asociación observada sea atribuible al azar es baja, cumpliéndose el criterio estadístico establecido para la contrastación de hipótesis. En consecuencia, la aceptación de la hipótesis se sustenta en la evidencia cuantitativa generada, sin establecer relaciones de causalidad, lo que permite afirmar que un mayor nivel de

implementación de estrategias de analítica predictiva se asocia con mayores niveles de personalización del aprendizaje, resaltando la relevancia de la analítica educativa como un componente estratégico dentro de los procesos formativos universitarios analizados. Se evidencia una correlación positiva moderada y estadísticamente significativa entre la analítica predictiva y el aprendizaje personalizado. Este resultado confirma la hipótesis general del estudio, al mostrar que un mayor nivel de implementación de estrategias de analítica predictiva se asocia con mayores niveles de personalización del aprendizaje en los estudiantes.

Desde una perspectiva conceptual, la analítica predictiva permite anticipar comportamientos académicos, identificar patrones de desempeño y detectar posibles dificultades de aprendizaje. Esta capacidad de anticipación resulta fundamental para diseñar intervenciones pedagógicas más ajustadas a las necesidades individuales del estudiante, tal como señalan (Sajja et al., 2023). En concordancia con Hernández-Sampieri et al. (2018), en investigaciones educativas de alcance correlacional, la identificación de asociaciones estadísticamente significativas permite comprender la relación entre variables sin establecer vínculos causales. En este sentido, la magnitud de la correlación obtenida resulta relevante desde el punto de vista práctico, al evidenciar la vinculación entre la analítica predictiva y el aprendizaje personalizado. Asimismo, Beltrán (2025) y Ortega (2023) sostienen que la integración del análisis de datos educativos en la educación superior fortalece la toma de decisiones pedagógicas basadas en evidencia. La relación observada respalda estas afirmaciones, al mostrar que la analítica predictiva se vincula con prácticas educativas más adaptativas y centradas en el estudiante. En

términos generales, los resultados ponen de manifiesto la relevancia de la analítica predictiva como un recurso estratégico para la personalización del aprendizaje en educación superior. El estudio contribuye al campo de la analítica educativa al aportar evidencia empírica que respalda el uso de datos para atender la diversidad de necesidades formativas, promoviendo modelos educativos más flexibles, inclusivos y orientados a la mejora continua.

Conclusiones

De los resultados mostrados, de su análisis y de su discusión, se pueden obtener las siguientes conclusiones: 1) Se identificó una correlación positiva baja entre la utilidad del Big Data y el aprendizaje personalizado ($r = 0.322$; $p < 0.001$; $n = 152$), lo que indica que su aprovechamiento se asocia con mayores niveles de personalización, aunque no es el único factor que influye en este proceso; 2) se evidenció una correlación positiva moderada entre la satisfacción con herramientas digitales y el aprendizaje personalizado ($r = 0.476$; $p < 0.001$; $n = 152$), mostrando que una valoración favorable de las plataformas tecnológicas se relaciona con una mejor adaptación del aprendizaje a las necesidades individuales; 3) se encontró una correlación positiva moderada entre la retroalimentación inmediata y el aprendizaje personalizado ($r = 0.423$; $p < 0.001$; $n = 152$), destacando la importancia de proporcionar información oportuna para ajustar el proceso formativo; 4) se determinó una correlación positiva moderada entre la analítica predictiva en conjunto y el aprendizaje personalizado ($r = 0.41$; $p < 0.05$; $n = 152$), lo que confirma que una mayor implementación de estrategias basadas en datos se asocia con mayores niveles de personalización del aprendizaje; y 5) los resultados evidenciaron una valoración alta de la analítica predictiva por

parte de los estudiantes, así como niveles elevados de aprendizaje personalizado en el contexto universitario. Las dimensiones de la analítica predictiva mostraron consistencia y relevancia como componentes estratégicos del proceso formativo, y la relación positiva moderada entre ambas variables confirmó que una mayor implementación de estrategias basadas en analítica educativa se asocia con mayores niveles de personalización del aprendizaje.

Agradecimientos

Los autores expresan su sincero agradecimiento a las instituciones académicas que contribuyeron al desarrollo de este trabajo, así como a los docentes y profesionales que brindaron orientación y apoyo durante el proceso investigativo. De igual manera, se reconoce el compromiso de las personas que participaron en el estudio, cuya colaboración fue fundamental para la realización de la investigación.

Referencias Bibliográficas

- Bellomo, S. (2023). Predictive analytics in higher education: AI-driven student success strategies. *Journal of Educational Data Science*, 5(2), 45–60.
- Davis, F. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
- De la Rosa, M. (2024). Desarrollo de una solución tecnológica de cursos inteligentes fundamentados en el modelo de aprendizaje personalizado y estilos de aprendizaje con machine learning. *Revista Iberoamericana de Tecnología Educativa*, 19(1), 55–70.
- Ferguson, R. (2019). Ethical challenges for learning analytics. *Journal of Learning Analytics*, 6(3), 25–30.
- Gándara, J., & Anahideh, R. (2025). Organizational knowledge and predictive analytics adoption in higher education.

- Computers & Education: Artificial Intelligence*, 6, 100185.
- García-Peña, F., Corell, A., Abella, V., & Grande, M. (2022). Learning analytics and higher education: A systematic literature review. *Education in the Knowledge Society*, 23, e28627. <https://doi.org/10.14201/eks.28627>
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1), 81–112. <https://doi.org/10.3102/003465430298487>
- Hernández-Sampieri, R., Fernández-Collado, C., & Baptista-Lucio, P. (2018). Metodología de la investigación (6.^a ed.). McGraw-Hill.
- Khalil, M., & Ebner, M. (2017). Learning analytics: Principles and constraints. In *Proceedings of the World Conference on Educational Multimedia, Hypermedia and Telecommunications* (pp. 59–68).
- Kim, J., Park, Y., & Cozart, J. (2018). Adaptive learning systems and educational data mining. *Educational Technology & Society*, 21(4), 30–45.
- Kivunja, C. (2023). Constructivism in the digital age: Implications for teaching and learning. *International Journal of Higher Education*, 12(2), 45–56.
- Liu, R., Liu, Q., & Liu, B. (2021). Artificial intelligence and predictive analytics in education: A systematic review. *IEEE Access*, 9, 78912–78928.
- Mayer, R. (2009). Multimedia learning (2nd ed.). Cambridge University Press.
- Mazhar, U. (2025). Innovation diffusion and AI adoption in higher education institutions. *Technology in Society*, 72, 102193.
- Méndez, L. (2022). Data-informed pedagogy: A framework for adaptive teaching. *Revista Latinoamericana de Innovación Educativa*, 14(2), 88–101.
- Nicol, D., & Macfarlane-Dick, D. (2006). Formative assessment and self-regulated learning. *Studies in Higher Education*, 31(2), 199–218.
- Ortega, P. (2023). Educación y equidad social en entornos digitales. *Revista Educación y Sociedad*, 41(3), 112–128.
- Ortega, J., Ramírez, L., & Torres, M. (2022). Digital transformation and learning analytics in Latin American universities. *Education and Information Technologies*, 27(4), 5673–5692.
- Panadero, E. (2022). A review of self-regulated learning: Six models and four directions for research. *Frontiers in Psychology*, 13, 422.
- Pardo, A., Han, F., & Ellis, R. (2019). Combining university student self-regulated learning indicators and engagement with online learning events. *IEEE Transactions on Learning Technologies*, 12(2), 219–232.
- Reigeluth, C., & Beatty, B. (2022). Instructional-design theories and models: The learner-centered paradigm of education. Routledge.
- Reyes-Parra, L., Castillo, D., & Pérez, M. (2024). Personalized learning supported by educational technology: A Latin American perspective. *Revista Electrónica de Investigación Educativa*, 26, e09.
- Rivas, G. (2023). Pertinencia de la investigación educativa en contextos digitales. *Revista Andina de Educación*, 7(1), 33–47.
- Rivera-Arzola, J. (2021). Personalized learning and student performance: Evidence from higher education. *Journal of Educational Technology Research*, 19(3), 201–215.
- Rogers, E. (2003). Diffusion of innovations (5th ed.). Free Press.
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355.
- Sajja, P., Parmar, J., & Patel, K. (2023). Integrating AI and learning analytics for data-driven pedagogical decisions and personalized interventions in education. *Education and Information Technologies*, 28, 12345–12368.
- Shute, V. (2008). Focus on formative feedback. *Review of Educational Research*, 78(1), 153–189.
- Siemens, G., & Baker, R. (2012). Learning analytics and educational data mining. In *Proceedings of the 2nd International*

Conference on Learning Analytics and Knowledge (pp. 252–254).

Vargas, M. (2024). Academic decision-making through predictive analytics. *Journal of Educational Innovation*, 8(1), 14–29.

Vargas, M., López, S., & Herrera, P. (2022). Learning analytics dashboards and academic performance. *Computers in Human Behavior Reports*, 6, 100167.

Velasco-Suárez, J., Moreno, A., & Paredes, D. (2023). Learning styles and adaptive digital

environments. *Education Sciences*, 13(5), 512.

Zimmerman, B. (2002). Becoming a self-regulated learner. *Theory Into Practice*, 41(2), 64–70.



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Eudes Leonidas Banchón Bohórquez, Kevin Alejandro Aveiga Rodríguez, Miguel Ángel Arce Calvache y Milton Alfonso Criollo Turusina.