

ORIGINAL

Predictive Analytics in Digital Marketing: A Statistical Modeling Approach for Predicting Consumer Behavior

Análisis Predictivo en Marketing Digital: Un Enfoque de Modelación Estadística para la Predicción del Comportamiento del Consumidor

Jazmín Isabel García-Guerra¹  , Héctor Oswaldo Aguilar-Cajas¹  , Heidy Elizabeth Vergara-Zurita¹  , Ana Lucía Rivera-Abarca¹  , Freddy Armijos-Arcos²  , José Israel López-Pumalema³  

¹Escuela Superior Politécnica de Chimborazo (ESPOCH), Riobamba - Ecuador.

²Ingeniería, Diseño y Consultoría (IDYC Cia. Ltda.)

³Universidad Estatal Península de Santa Elena.

Citar como: García-Guerra JI, Aguilar-Cajas HO, Vergara-Zurita HE, Rivera-Abarca AL, Armijos-Arcos F, López-Pumalema JI. Predictive Analytics in Digital Marketing: A Statistical Modeling Approach for Predicting Consumer Behavior. Data and Metadata. 2025; 4:1061. <https://doi.org/10.56294/dm20251061>

Enviado: 03-10-2024

Revisado: 18-02-2025

Aceptado: 09-06-2025

Publicado: 10-06-2025

Editor: Dr. Adrián Alejandro Vitón Castillo 

Autor para la correspondencia: Jazmín Isabel García-Guerra 

ABSTRACT

Introduction: the evolution of predictive analytics in digital marketing is deeply rooted in the development of statistical modeling and data analytics.

Objectives: the objective of the present research was to analyze the use of advanced statistical models for predicting consumer behavior in digital marketing environments, highlighting the relevance of predictive analytics in data-driven strategic decision making.

Method: five machine learning, logistic regression, decision tree, random forest, support vector machines (SVM) and neural networks models were evaluated on a synthetic dataset representative of digital consumers belonging to Generation Z. The analysis considered key metrics such as overall accuracy, cross-validation mean and standard deviation, in order to measure both the effectiveness and stability of each model.

Results: the results showed that the logistic regression, Random Forest, SVM and neural network models achieved an accuracy of 97 % with overall consistency (standard deviation of 0,0), positioning them as reliable tools for predicting consumption trends. In contrast, the decision tree showed lower accuracy (92 %) and higher variability, which limits its applicability in complex scenarios.

Conclusion: the study concludes that the combination of accuracy and stability is essential for the implementation of effective predictive models in digital marketing and also highlights the importance of integrating these models into campaign automation and personalization systems to anticipate preferences, improve customer experience and optimize resources.

Keywords: Predictive Analytics; Digital Marketing; Consumer Behavior; Machine Learning; Statistical Modeling.

RESUMEN

Introducción: la evolución del análisis predictivo en el marketing digital está profundamente arraigada en el desarrollo de la modelización estadística y el análisis de datos.

Objetivo: el objetivo de la presente investigación fue analizar el uso de modelos estadísticos avanzados para la predicción del comportamiento del consumidor en entornos de marketing digital, destacando la relevancia del análisis predictivo en la toma de decisiones estratégicas basadas en datos.

Método: se evaluaron cinco modelos de aprendizaje automático, regresión logística, árbol de decisión, bosque aleatorio, máquinas de vectores de soporte (SVM) y redes neuronales sobre un conjunto sintético de datos representativo de consumidores digitales pertenecientes a la Generación Z. El análisis consideró métricas clave como la precisión global (accuracy), la media de validación cruzada y la desviación estándar, con el objetivo de medir tanto la eficacia como la estabilidad de cada modelo.

Resultados: los resultados mostraron que los modelos de regresión logística, Random Forest, SVM y redes neuronales alcanzaron una precisión del 97 % con consistencia total (desviación estándar de 0,0), posicionándolos como herramientas confiables para la predicción de tendencias de consumo. En cambio, el árbol de decisión evidenció una menor precisión (92 %) y mayor variabilidad, lo que limita su aplicabilidad en escenarios complejos.

Conclusión: el estudio concluye que la combinación de precisión y estabilidad es esencial para la implementación de modelos predictivos efectivos en marketing digital también destaca la importancia de integrar estos modelos en sistemas de automatización y personalización de campañas, para anticipar preferencias, mejorar la experiencia del cliente y optimizar recursos.

Palabras clave: Análisis Predictivo; Marketing Digital; Comportamiento del Consumidor; Aprendizaje Automático; Modelado Estadístico.

INTRODUCCIÓN

La evolución del análisis predictivo en el marketing digital está profundamente arraigada en el desarrollo de la modelización estadística y el análisis de datos. En su núcleo, el análisis predictivo emplea datos históricos para predecir resultados futuros, aprovechando diversos modelos estadísticos, técnicas de aprendizaje automático y métodos de extracción de datos para analizar tendencias y patrones en el comportamiento del consumidor.^(1,2)

La integración de estas metodologías ha transformado el panorama de la investigación de marketing, particularmente con la llegada de los “Big Data”, que ha mejorado significativamente la capacidad de reunir y analizar grandes cantidades de información del consumidor.^(3,4)

Históricamente, la base del análisis predictivo se remonta a las primeras aplicaciones de las técnicas estadísticas en el marketing. A medida que las empresas comenzaron a reconocer el valor de la toma de decisiones basada en datos, se hizo hincapié en el uso de datos secundarios procedentes de informes y estudios de mercado. Este enfoque, aunque menos directo que la recopilación de datos primarios, proporcionó a los especialistas en comercialización una perspectiva más amplia sobre las tendencias del mercado y los patrones de consumo.^(5,6)

La llegada de capacidades más sofisticadas de procesamiento de datos permitió a los especialistas en comercialización realizar análisis cuantitativos y cualitativos. El análisis cuantitativo se centra en los datos numéricos para identificar tendencias y correlaciones, utilizando software estadístico y plataformas de análisis.^(7,8) Por el contrario, el análisis cualitativo trata de comprender las motivaciones y actitudes subyacentes de los consumidores, a menudo derivadas de entrevistas y respuestas a encuestas abiertas. Este doble enfoque ha sido fundamental para sintetizar la información a fin de obtener conocimientos significativos que sirvan de base a las estrategias comerciales.

Con los avances en la tecnología y el auge del aprendizaje automático, el modelado predictivo se ha convertido en un aspecto central de las estrategias de marketing. Técnicas como la regresión lineal, la regresión logística y los árboles de decisión han permitido a los especialistas en marketing desarrollar modelos que no solo predicen resultados futuros, sino que también mejoran la comprensión del comportamiento del consumidor.^(9,10) Estos modelos han demostrado una considerable eficacia en el marketing digital, permitiendo a las empresas adaptar sus estrategias para satisfacer las necesidades y preferencias específicas de sus clientes, lo que en última instancia conduce a un mayor compromiso del cliente y al crecimiento del negocio.^(11,12)

El análisis predictivo en el marketing digital aprovecha los modelos estadísticos para pronosticar el comportamiento del consumidor, lo que permite a las empresas tomar decisiones informadas. Al utilizar grandes cantidades de datos digitales, el análisis predictivo identifica las tendencias y los patrones que sirven de base para las estrategias de marketing. Este enfoque no solo mejora la comprensión de las preferencias de los consumidores, sino que también ayuda a optimizar la asignación de recursos y a mejorar la participación de los clientes, por lo cual el objetivo de esta investigación fue evaluar el uso del análisis Predictivo en Marketing Digital bajo un enfoque de modelación estadística para la predicción del comportamiento del consumidor

MÉTODO

Se aplicó el análisis predictivo, dado que implica el uso de técnicas estadísticas para analizar datos históricos y hacer pronósticos sobre el comportamiento futuro. Este proceso puede mejorar significativamente la toma de

decisiones estratégicas en el marketing digital al ofrecer información sobre las preferencias de los clientes y las tendencias del mercado. Las principales metodologías utilizadas en el análisis predictivo incluyeron análisis de regresión, modelos de clasificación, árboles de decisión y redes neuronales, cada uno de los cuales sirve a fines distintos en el proceso de análisis

Modelos estadísticos evaluados

Análisis de regresión

El análisis de regresión es uno de los métodos estadísticos que se empleó en la modelización predictiva, dado que identifica las relaciones entre las variables y ayuda a prever los resultados sobre la base de datos históricos, para ello se usaron técnicas tales como la regresión lineal y la regresión logística son particularmente valiosas para estimar la demanda del mercado y predecir el valor de vida útil del cliente y que pueden determinar cómo factores como el precio y las estrategias promocionales influyen en el rendimiento de las ventas.

Modelos de clasificación

Se evaluaron algoritmos como árboles de decisión y máquinas vectoriales de apoyo, los especialistas en marketing pueden identificar eficazmente segmentos de clientes de alto valor, adaptar las actividades de marketing y optimizar la orientación publicitaria. Este enfoque específico permite estrategias de marketing personalizadas que resuenen con segmentos específicos de audiencia, mejorando en última instancia el compromiso del cliente y las tasas de conversión.

Árboles de decisión

Los árboles de decisión fueron considerados dado que son modelos intuitivos que representan decisiones y sus posibles consecuencias en una estructura similar a un árbol. Cada rama significa una elección, mientras que las hojas representan resultados específicos. Este método es particularmente útil para la toma de decisiones rápidas y puede manejar fácilmente múltiples variables, por lo que es ideal para los vendedores que necesitan evaluar varios factores que influyen en el comportamiento del consumidor.

Redes neuronales

Las redes neuronales fueron evaluadas dada que son modelos avanzados de aprendizaje automático que permiten el reconocimiento de patrones complejos dentro de grandes conjuntos de datos. Son particularmente eficaces para identificar relaciones no lineales y pueden validar las predicciones hechas por modelos de regresión y árboles de decisión. Al emplear redes neuronales, los especialistas en marketing pueden lograr una mayor precisión en la predicción del comportamiento y las preferencias de los consumidores, lo que mejora la eficacia general del marketing.

Análisis de series temporales

Dentro del análisis predictivo, se consideraron los modelos de series temporales, dado que los mismos analizan puntos de datos recopilados a lo largo del tiempo para identificar tendencias y estacionalidad, permitiendo a los especialistas en marketing tomar decisiones informadas basadas en el rendimiento futuro previsto, permitiendo a las empresas pueden prever las fluctuaciones de ventas y preparar estrategias de comercialización que se ajusten a los picos de demanda previstos.

Datos utilizados

El análisis se basa en un conjunto de datos sintéticos que simula el comportamiento de consumidores digitales, específicamente enfocado en la Generación Z (18-24 años). El dataset comprendió 1,000 registros con las siguientes características:

Variables Demográficas

Edad: distribuida normalmente con media de 21 años y desviación estándar de 2 años, *género*: distribución binaria (M/F), *ingresos*: Distribución log-normal con base de 10,000 unidades monetarias, *educación*: categorizada en tres niveles (Secundaria 40 %, Terciaria 20 %, Otros 40 %) y *región*: segmentada en cinco zonas geográficas (Norteamérica, Europa, Asia-Pacífico, Latinoamérica, África)

Variables Comportamentales

Frecuencia de compra: Distribución de Poisson con $\lambda=1$ (promedio mensual), tiempo de carga del sitio: distribución exponencial con escala de 2 unidades, tiempo en el sitio: distribución exponencial con escala de 5 minutos, *interacciones con anuncios*: distribución uniforme entre 5 y 10 interacciones, *tasa de conversión*: distribución binaria con probabilidad de conversión del 3 % y monto de compra: para usuarios convertidos, distribución normal con media de 75 unidades monetarias y desviación estándar de 25.

Este conjunto de datos simulo un escenario realista de comercio electrónico, incorporando tanto aspectos demográficos como comportamentales del consumidor digital, con especial énfasis en el segmento juvenil del mercado.

RESULTADOS

En el marco del estudio titulado “Análisis Predictivo en Marketing Digital: Un Enfoque de Modelación Estadística para la Predicción del Comportamiento del Consumidor”, se llevó a cabo una comparación detallada entre cinco modelos de aprendizaje automático ampliamente reconocidos por su eficacia en tareas de clasificación: Regresión Logística, Árbol de Decisión, Bosque Aleatorio (Random Forest), Máquina de Vectores de Soporte (SVM) y Red Neuronal. El propósito central fue evaluar qué tan bien estos modelos pueden anticipar el comportamiento del consumidor en plataformas digitales, un aspecto crucial para la toma de decisiones estratégicas en campañas de marketing orientadas por datos (figura 1).




Figura 1. Comparación de precisión entre modelos

Para ello, se emplearon tres indicadores fundamentales que permiten valorar no solo la precisión del modelo, sino también su estabilidad a lo largo de múltiples iteraciones: la precisión global (Accuracy), la media de validación cruzada (CV Mean) y la desviación estándar de la validación cruzada (CV Std). Estos parámetros proporcionan una visión más completa sobre el rendimiento general del modelo y su capacidad para generalizar correctamente a nuevos datos como se puede observar en la figura 2.




Figura 2. Distribución de montos de compra

Los resultados obtenidos fueron notoriamente consistentes entre cuatro de los cinco modelos evaluados. Específicamente, la Regresión Logística, el Bosque Aleatorio, el SVM y la Red Neuronal lograron una precisión del 97 %, tanto en los datos de prueba como en la media de la validación cruzada. Además, todos ellos mostraron una desviación estándar de 0,0, lo que indica que su rendimiento fue estable en cada pliegue de la validación cruzada. Esta uniformidad sugiere que dichos modelos no solo son precisos, sino también confiables para ser implementados en contextos reales donde los datos pueden ser complejos y variados, como ocurre en el marketing digital (figura 3).




Figura 3. Segmentación de clientes

En contraste, el Árbol de Decisión presentó un rendimiento inferior, alcanzando una precisión del 92 % y una media de validación cruzada ligeramente superior a 0.926. A diferencia del resto de modelos, mostró una desviación estándar de aproximadamente 0,0103, lo que evidencia una mayor variabilidad en su comportamiento frente a distintas particiones de los datos. Esta sensibilidad podría deberse a su estructura inherente, que tiende a ajustarse con mayor rigidez a los datos de entrenamiento, haciéndolo potencialmente más propenso al sobreajuste y menos eficaz para modelar dinámicas de consumo más complejas o ruidosas.




Figura 4. Importancia de variables

Desde una perspectiva aplicada, los resultados destacan la solidez de modelos como el Random Forest y la Red Neuronal, que no solo mantienen una alta precisión, sino que lo hacen de manera consistente. Esto es especialmente valioso en el entorno digital, donde pequeñas fluctuaciones en el comportamiento del consumidor pueden representar grandes oportunidades o pérdidas para una empresa. Contar con modelos predictivos confiables permite segmentar audiencias de forma más precisa, adaptar mensajes publicitarios en tiempo real y optimizar recursos, incrementando así la eficacia de las campañas publicitarias y la rentabilidad de las estrategias de marketing.




Figura 5. Tasa de conversión por región

En definitiva, este análisis evidencia que no basta con evaluar únicamente la precisión de un modelo. También es crucial considerar su estabilidad, su capacidad de generalización y su rendimiento consistente ante diferentes muestras de datos. Estas cualidades son las que realmente determinan el valor práctico de un modelo predictivo cuando se aplica en escenarios reales y dinámicos como el marketing digital contemporáneo.

DISCUSIÓN

Los resultados obtenidos en este estudio confirman el potencial de la analítica predictiva como herramienta clave para anticipar el comportamiento del consumidor en entornos digitales. En particular, los modelos de Regresión Logística, Random Forest, SVM y Redes Neuronales demostraron un desempeño sobresaliente en términos de precisión (97 %) y estabilidad (desviación estándar de 0,0), lo cual sugiere que son capaces de generalizar eficazmente a nuevos conjuntos de datos. Esta capacidad predictiva consistente es fundamental en el ámbito del marketing digital, donde las decisiones deben adaptarse rápidamente a los cambios del mercado y a las variaciones en las preferencias de los usuarios.^(13,14)

Estos hallazgos coinciden con lo reportado por quienes afirman que los modelos basados en aprendizaje automático han transformado la forma en que las empresas comprenden y anticipan los patrones de consumo, mejorando significativamente la toma de decisiones estratégicas.⁽¹⁵⁾ Asimismo, señalan que la estabilidad del modelo es tan importante como su precisión, ya que evita que las decisiones empresariales se basen en fluctuaciones aleatorias o ruido de los datos.⁽¹⁶⁾

El rendimiento inferior del Árbol de Decisión, que obtuvo una precisión del 92 % y una desviación estándar superior a 0,01, resalta un aspecto crítico del modelado estadístico: no todos los algoritmos responden igual de bien ante estructuras de datos complejas. Su comportamiento más volátil puede atribuirse a una menor capacidad de generalización y a una mayor tendencia al sobreajuste.^(17,18) Aunque es un modelo interpretable y de fácil implementación, su sensibilidad ante cambios mínimos en los datos puede limitar su utilidad en escenarios dinámicos como el marketing digital, donde la consistencia es clave.

Desde una perspectiva aplicada, estos resultados no solo aportan valor académico, sino también implicaciones prácticas relevantes para equipos de marketing. Por ejemplo, la implementación de modelos robustos como las Redes Neuronales o los Bosques Aleatorios permite automatizar la segmentación de audiencias, anticipar la probabilidad de compra o abandono, y personalizar mensajes en tiempo real. Estas capacidades se alinean con lo planteado por quienes destacan cómo la analítica predictiva puede mejorar la experiencia del cliente y aumentar la eficiencia de las campañas publicitarias.^(19,20)

Además, al considerar el papel de la psicología del consumidor en el diseño de estrategias digitales, se refuerza la idea de que los modelos predictivos deben capturar no solo datos transaccionales, sino también variables de comportamiento, contexto emocional e incluso señales sociales recogidas de redes digitales. Esto es especialmente importante en una era donde los consumidores esperan interacciones cada vez más personalizadas y relevantes.^(21,22)

El éxito de una estrategia predictiva no reside únicamente en seleccionar el modelo más preciso, sino en garantizar que este mantenga su rendimiento a lo largo del tiempo y en distintos segmentos de consumidores. Esta afirmación se ve reflejada en el presente análisis, donde la combinación entre alta precisión y baja variabilidad refuerza la confiabilidad de ciertos algoritmos en escenarios reales de implementación.^(23,24)

Por último, este estudio también pone de relieve la necesidad de integrar herramientas de análisis predictivo dentro de plataformas de automatización y gestión de campañas. Plataformas que permiten retroalimentación

constante del rendimiento del modelo y ajustes automáticos según las nuevas tendencias resultan esenciales para que las predicciones no pierdan vigencia y sigan generando valor competitivo.^(25,26)

En resumen, la discusión de estos resultados permite concluir que, en el contexto del marketing digital moderno, los modelos de aprendizaje automático deben ser evaluados más allá de la métrica de precisión. Su utilidad práctica depende también de su estabilidad, flexibilidad y capacidad para adaptarse a un ecosistema digital en constante evolución. Este enfoque multidimensional, respaldado por la literatura actual.^(27,28,29) Contribuye a construir sistemas predictivos más eficaces, sostenibles y centrados en el usuario.

CONCLUSIONES

Este estudio permitió evidenciar el valor estratégico de los modelos de aprendizaje automático aplicados al análisis predictivo en marketing digital, con énfasis en la predicción del comportamiento del consumidor. A través de la comparación de cinco modelos ampliamente utilizados —Regresión Logística, Árbol de Decisión, Bosque Aleatorio, SVM y Red Neuronal— se demostró que, más allá de la precisión como indicador aislado, la estabilidad del rendimiento y la capacidad de generalización de un modelo son factores determinantes para su implementación efectiva en contextos reales.

Los modelos de Regresión Logística, Random Forest, SVM y Redes Neuronales mostraron un desempeño sobresaliente, no solo por alcanzar una precisión del 97 %, sino también por mantener una desviación estándar nula, lo cual evidencia una notable robustez frente a variaciones en los datos. Estas cualidades hacen que estos algoritmos sean especialmente adecuados para entornos digitales complejos y cambiantes, donde las decisiones deben tomarse rápidamente y con un alto nivel de confianza, en cambio, el Árbol de Decisión, aunque útil por su interpretabilidad, mostró mayor sensibilidad a la variabilidad de los datos, lo cual podría limitar su aplicabilidad en estrategias de marketing que requieren precisión constante y respuestas adaptativas.

Desde una perspectiva práctica, los resultados de esta investigación refuerzan la importancia de incorporar soluciones predictivas en los procesos de segmentación, personalización de campañas, análisis de abandono y fidelización. Estas herramientas permiten a las empresas anticiparse a las necesidades y decisiones de sus consumidores, optimizando la asignación de recursos y fortaleciendo la relación con sus audiencias, por lo que se concluye que el verdadero poder de la analítica predictiva en marketing no reside únicamente en la capacidad técnica de los modelos, sino en cómo se integran en la toma de decisiones estratégicas para generar valor sostenido y centrado en el cliente. Para lograrlo, es indispensable continuar fomentando una cultura organizacional orientada por datos, apoyada por herramientas tecnológicas, pero también por una comprensión profunda de las dinámicas humanas que definen el consumo en la era digital.

REFERENCIAS

1. Theodorakopoulos L, Theodoropoulou A. Leveraging big data analytics for understanding consumer behavior in digital marketing: A systematic review. *Hum Behav Emerg Technol*. 2024;2024(1):3641502. doi: <http://10.1155/2024/3641502>.
2. Chkoniya V. Challenges in decoding consumer behavior with data science. *Eur J Econ Bus Stud*. 2021;7(1):140-53. doi: <http://10.26417/897ovg79t>.
3. Chaudhary K, Alam M, Al-Rakhami MS, Gumaei A. Machine learning-based mathematical modelling for prediction of social media consumer behavior using big data analytics. *J Big Data*. 2021;8(1):73. doi: <http://10.1186/s40537-021-00466-2>.
4. Gan M, Ouyang Y. Study on tourism consumer behavior characteristics based on big data analysis. *Front Psychol*. 2022;13:876993. doi: <http://10.3389/fpsyg.2022.876993>.
5. Włodarczyk K. Trends of evolution in consumer behavior in the contemporary world. *Probl Zarządzania*. 2021;19(1):39-50. doi: <http://10.7172/1644-9584.91.3>.
6. Gabhane D, Varalaxmi P, Rathod U, Hamida AGB, Anand B. Digital marketing trends: Analyzing the evolution of consumer behavior in the online space. *Bol Lit Oral*. 2023;10(1):462-73. Available from: https://www.rgcms.edu.in/wp-content/uploads/2023/10/52_TITLE126.pdf
7. Liu H. Big data precision marketing and consumer behavior analysis based on fuzzy clustering and PCA model. *J Intell Fuzzy Syst*. 2021;40(4):6529-39. doi: <http://10.3233/JIFS-189491>.
8. Rozenkowska K. Theory of planned behavior in consumer behavior research: A systematic literature review. *Int J Consum Stud*. 2023;47(6):2670-700. doi: <http://10.1111/ijcs.12970>.

9. Sunarya PA, Rahardja U, Chen SC, Li YM, Hardini M. Deciphering digital social dynamics: A comparative study of logistic regression and random forest in predicting e-commerce customer behavior. *J Appl Data Sci.* 2024;5(1):100-13. doi: <http://10.47738/jads.v5i1.155>.
10. Xiao S, Tong W. Prediction of user consumption behavior data based on the combined model of TF-IDF and logistic regression. *J Phys Conf Ser.* 2021;1757(1):012089. doi: <http://10.1088/1742-6596/1757/1/012089>.
11. Mehrolia S, Alagarsamy S, Solaikutty VM. Customers response to online food delivery services during COVID-19 outbreak using binary logistic regression. *Int J Consum Stud.* 2021;45(3):396-408. doi: <http://10.1111/ijcs.12630>.
12. Arumugam T, Hameed SS, Sanjeev MA. Buyer behaviour modelling of rural online purchase intention using logistic regression. *Int J Manag Enterp Dev.* 2023;22(2):139-57. doi: <http://10.1504/IJMED.2023.130153>.
13. Kasem MS, Hamada M, Taj-Eddin I. Customer profiling, segmentation, and sales prediction using AI in direct marketing. *Neural Comput Appl.* 2024;36(9):4995-5005. doi: <http://10.1007/s00521-023-09339-6>.
14. Habil S, El-Deeb S, El-Bassiouny N. AI-based recommendation systems: the ultimate solution for market prediction and targeting. In: *The Palgrave handbook of interactive marketing*. Cham: Springer; 2023. p. 683-704. Available from: https://www.researchgate.net/publication/388871670_AI_and_Machine_Learning_in_Multimedia_Platforms_Present_Applications_and_Future_Implications
15. Chakravarthy BS, Perlmutter HV. Strategic planning for a global business. *Int Strateg Manag.* 2023;29-42. doi: <http://10.4324/9781315058993-4>.
16. Zhang H, Zang Z, Zhu H, Uddin MI, Amin MA. Big data-assisted social media analytics for business model for business decision making system competitive analysis. *Inf Process Manag.* 2022;59(1):102762. doi: <http://10.1016/j.ipm.2021.102762>.
17. Hu J, Szymczak S. A review on longitudinal data analysis with random forest. *Brief Bioinform.* 2023;24(2):bbad002. doi: <http://10.1093/bib/bbad002>.
18. Sun Z, Wang G, Li P, Wang H, Zhang M, Liang X. An improved random forest based on the classification accuracy and correlation measurement of decision trees. *Expert Syst Appl.* 2024;237:121549. doi: <http://10.1016/j.eswa.2023.121549>.
19. De Araujo Morais LR, da Silva Gomes GS. Neural Network-Enhanced Decision Support: Investigating Prediction Intervals for Real-Time Digital Marketing Return on Investment Data. In: *Brazilian Workshop on Social Network Analysis and Mining (BraSNAM)*. SBC; 2024. p. 47-60. doi: <http://10.5753/brasnam.2024.2232>.
20. Mejía Trejo J. Digital marketing model innovation and Generation Z as consumer decision-making style. Making predictions with an artificial neural network, in Mexico. *Contad Adm.* 2021;66(4). doi: <http://10.22201/fca.24488410e.2021.3258>.
21. Ferreira JJ, Fernandes CI, Rammal HG, Veiga PM. Wearable technology and consumer interaction: A systematic review and research agenda. *Comput Hum Behav.* 2021;118:106710. doi: <http://10.1016/j.chb.2021.106710>.
22. Mogaji E, Balakrishnan J, Nwoba AC, Nguyen NP. Emerging-market consumers' interactions with banking chatbots. *Telemat Inform.* 2021;65:101711. doi: <http://10.1016/j.tele.2021.101711>.
23. Khan M, Ahmad M, Alidjonovich RD, Bakhritdinovich KM, Turobjonovna KM, Odilovich IJ. The impact of cultural factors on digital marketing strategies with Machine learning and honey bee Algorithm (HBA). *Cogent Bus Manag.* 2025;12(1):2486590. doi: <http://10.1080/23311975.2025.2486590>.
24. Wang G. Customer segmentation in the digital marketing using a Q-learning based differential evolution algorithm integrated with K-means clustering. *PLoS One.* 2025;20(2):e0318519. doi: <http://10.1371/journal.pone.0318519>.

25. Kasem MS, Hamada M, Taj-Eddin I. Customer profiling, segmentation, and sales prediction using AI in direct marketing. *Neural Comput Appl*. 2024;36(9):4995-5005. doi: <http://10.1007/s00521-023-09339-6>.
26. Sharma A, Fadahunsi A, Abbas H, Pathak VK. A multi-analytic approach to predict social media marketing influence on consumer purchase intention. *J Indian Bus Res*. 2022;14(2):125-49. doi: <http://10.1108/JIBR-08-2021-0313>.
27. Ullal MS, Hawaldar IT, Soni R, Nadeem M. The role of machine learning in digital marketing. *SAGE Open*. 2021;11(4):21582440211050394. doi: <http://10.1177/21582440211050394>.
28. Berlilana B, Hariguna T, El Emary IM. Enhancing Digital Marketing Strategies with Machine Learning for Analyzing Key Drivers of Online Advertising Performance. *J Appl Data Sci*. 2025;6(2):817-27. doi: <http://10.47738/jads.v6i2.658>.
29. Gutnik S. Application of data mining and machine learning methods to enhance the effectiveness of digital marketing strategies. In: *Digital Strategies in a Global Market: Navigating the Fourth Industrial Revolution*. 2021. p. 131-44. doi: http://10.1007/978-3-030-58267-8_10.

FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación.

CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Jazmín Isabel García-Guerra.

Curación de datos: Jazmín Isabel García-Guerra.

Análisis formal: Héctor Aguilar-Cajas.

Investigación: Héctor Aguilar-Cajas.

Metodología: Héctor Aguilar-Cajas.

Administración del proyecto: Héctor Aguilar-Cajas.

Recursos: Ana Lucía Rivera-Abarca.

Software: Ana Lucía Rivera-Abarca.

Supervisión: Ana Lucía Rivera-Abarca.

Validación: Jazmín Isabel García-Guerra. *Visualización:* Jazmín Isabel García-Guerra.

Redacción - borrador original: Freddy Armijos-Arcos, José Israel López-Pumalema.

Redacción - revisión y edición: Freddy Armijos-Arcos, José Israel López-Pumalema.