

Inteligencia artificial en la personalización del marketing

Artificial intelligence in marketing personalization

Núñez, Maritza

Universidad de Panamá, Panamá.

majunu71@gmail.com, <https://orcid.org/0000-0002-2287-314X>

Recibido: 27-08-24, Aceptado: 10-12-24

DOI: <https://doi.org/10.48204/j.saber.v8n1.a6797>

Resumen

Este estudio explora cómo la inteligencia artificial está transformando la personalización en el marketing. el objetivo principal fue desarrollar lineamientos para el diseño de algoritmos de aprendizaje automático que analicen en tiempo real el comportamiento y preferencias de los consumidores. Con un estudio documental, descriptivo, mixto y exploratorio, el resultado principal mostró que la implementación de la IA en marketing mejora la experiencia del usuario y aumenta la tasa de conversión al permitir una personalización dinámica y adaptativa. Sin embargo, también mostró las consideraciones éticas y de privacidad para garantizar que los datos de los consumidores sean utilizados de manera responsable y transparente, concluyendo que para utilizar IA en marketing hay que equilibrar la innovación tecnológica con la responsabilidad ética, fortaleciendo la relación entre las marcas y los consumidores.

Palabras Clave: inteligencia artificial, aprendizaje automático, marketing de contenido, personalización de marketing.

Abstract

This study explores how artificial intelligence is transforming personalization in marketing. The main objective was to develop guidelines for the design of machine learning algorithms that analyze consumer behavior and preferences in real time. With a documentary, descriptive, mixed and exploratory study, the main result showed that the implementation of AI in marketing improves the user experience and increases the conversion rate by allowing dynamic and adaptive personalization. However, it also

showed the ethical and privacy considerations to ensure that consumer data is used responsibly and transparently, concluding that to use AI in marketing, technological innovation must be balanced with ethical responsibility, strengthening the relationship between brands and consumers.

Keywords: artificial intelligence, machine learning, content marketing, marketing personalization.

Introducción

La personalización en el marketing contemporáneo se ha convertido en un factor que se utiliza para captar y mantener la atención de los consumidores (Rojas Rojas & Diaz Cadena, 2023). La evolución de la tecnología ha ayudado a desarrollar de manera más sencilla los algoritmos de aprendizaje automático (*machine learning*) capaces de analizar en tiempo real el comportamiento y las preferencias de los consumidores (Mirjalili & Raschka, 2020). Este artículo tiene como objetivo presentar lineamientos para el diseño de estos algoritmos, creados para conocer cómo el profesional en marketing puede ofrecer recomendaciones personalizadas que mejoren la experiencia del usuario, y aumenten la tasa de conversión y la satisfacción general del cliente de manera automática, administrando el proceso con la inteligencia artificial.

El problema principal que enfrenta el marketing actual es la capacidad de las empresas para ofrecer experiencias personalizadas que se adapten a las necesidades y preferencias individuales de los consumidores en tiempo real. La cantidad creciente de datos generados por los usuarios en plataformas digitales lleva a un análisis eficiente para transformar esta información en recomendaciones relevantes y oportunas. Sin embargo, muchas organizaciones todavía luchan por implementar sistemas efectivos que puedan procesar estos datos y traducirlos en estrategias de marketing efectivas.

La importancia de esta investigación la establece su potencial para ofrecer una manera más de mostrar de qué manera las empresas son capaces de innovar para concentrarse en la personalización en marketing, que no es un asunto sencillo de tratar. Los algoritmos de aprendizaje automático pueden transformar grandes volúmenes de datos utilizados

por las empresas para diseñar estrategias centradas en el cliente. Al establecer lineamientos claros para el desarrollo de estos algoritmos, esta investigación pretende ofrecer un marco práctico y teórico que facilite la implementación de soluciones de personalización avanzada. Además, “la mayoría de los estudios de inteligencia artificial (67%) demuestran el escenario de uso de la tecnología IA en el análisis predictivo y la automatización del marketing digital” (Alimkhodjaeva, 2022, p. 117).

El alcance de esta investigación abarca el análisis de las técnicas de aprendizaje automático aplicadas a la personalización en marketing, con un enfoque en la creación de recomendaciones en tiempo real. Los autores que han escrito sobre este tema en las etapas más recientes han expuesto diversas metodologías y evalúan sus implicaciones prácticas, su impacto en la tasa de conversión y la satisfacción del cliente. Este estudio también considera aspectos éticos y de privacidad relacionados con la recolección y el uso de los datos personales, tal como menciona Solove (2010), que la privacidad es uno de los conceptos más importantes en la actualidad, pero también es uno de los más elusivos.

Existen estudios que han demostrado el impacto positivo en la personalización del marketing; por ejemplo, una investigación realizada por Kumar & Reinartz (2016) destaca que las recomendaciones personalizadas pueden mejorar significativamente la tasa de conversión y la lealtad del cliente al ofrecer experiencias más relevantes y adaptadas a sus intereses. También se puede citar el trabajo de Ricci *et al.* (2015), que proporciona una visión integral sobre los sistemas de recomendación, incluyendo técnicas basadas en el filtrado colaborativo y contenido, así como métodos híbridos que combinan múltiples enfoques para mejorar la precisión de las recomendaciones (Burke, 2002). Con referencia al aprendizaje automático, el estudio de Zhang *et al.* (2019) explora el uso de redes neuronales profundas para la personalización en tiempo real, resaltando cómo los modelos avanzados pueden capturar patrones complejos en los datos de los consumidores y ofrecer recomendaciones más precisas.

Materiales y métodos

El enfoque de este estudio es exploratorio y descriptivo, con una combinación de análisis cualitativo y cuantitativo. Se usó un enfoque mixto inductivo para entender las técnicas y herramientas tecnológicas detrás de la personalización mediante inteligencia artificial, y su influencia en la experiencia del usuario y las métricas de marketing. Por eso, el diseño de la investigación siguió una estructura documental y teórica, complementada con análisis de datos secundarios. Se revisaron fuentes académicas (libros, artículos científicos y estudios de mercado) utilizando las variables 'inteligencia artificial', 'aprendizaje automático', 'personalización en marketing', y 'ética y privacidad' como variables.

Los datos se recopilaron a partir de la revisión de la literatura existente y estudios de casos relevantes en el área de la inteligencia artificial aplicada al marketing. Se utilizó la técnica documental en la etapa inicial con búsqueda, selección, organización y asimilación de la información, para validar la información y eliminar los documentos que, por su origen o falta de acceso limitaban la verificación de los datos presentados (Martínez Miguélez, 2006). Luego se interpretó la información desde una visión cualitativa (Balcázar Nava, 2013) para contextualizar el enfoque que se le quería dar a la investigación; se esquematizaron las ideas y se creó la estructura base de las secciones del artículo. Luego, se aplicó la técnica analítica para extraer los datos cuantitativos que proporcionaran más precisión en la descripción de los datos. Finalmente, se aplicó un nuevo análisis y se utilizó la investigación narrativa (Chase, 2015) para saber cómo redactar información del área tecnológica entendible para el área de marketing y poder aplicar los ejemplos.

Resultados

Como las experiencias personalizadas mejoran la satisfacción, el 68% de los consumidores cambian a quien le ofrezca una mejor experiencia de este tipo y para ello utilizan inteligencia artificial (Rollins & Amato, 2024). Al hablar acerca de los lineamientos para el diseño de algoritmos de aprendizaje automático en la personalización del marketing, se deben considerar estas 5 etapas: 1) recopilación y preparación de datos; 2) selección e implementación de algoritmos; 3) evaluación y optimización de modelos; 4) implementación y monitoreo en tiempo real; 5) consideraciones éticas y de privacidad.

1) Recopilación y preparación de datos. El primer paso es la recopilación de datos, porque es necesario obtener datos detallados sobre el comportamiento del consumidor. La literatura muestra que se pueden incluir clics en anuncios, historiales de navegación, compras anteriores, valoraciones de productos y comentarios. Este tipo de datos debe ser recolectado en tiempo real para permitir una respuesta rápida a las preferencias del usuario que nunca son estáticas y cambian de acuerdo con las tendencias. Se deben tener datos detallados del comportamiento del consumidor para personalizar las recomendaciones (Han *et al.*, 2011). En la Tabla 1 se presentan los tipos de datos que se deben recopilar y su frecuencia recomendada:

Tabla 1

Tipos de datos que se deben recopilar con la frecuencia de actualización

Tipo de datos	Descripción	Frecuencia de actualización
Clics en anuncios	Registra los anuncios en los que los usuarios hacen clics	En tiempo real
Historial de navegación	Datos sobre las páginas web visitadas por el usuario	En tiempo real

Compras anteriores	Información sobre productos comprados por el usuario	Mensual
Valoraciones de productos	Calificaciones y reseñas que los usuarios han dejado	Mensual
Comentarios	Texto libre de comentarios y opiniones de los usuarios	En tiempo real

Nota. Basado en Han *et al.* (2011).

¿Cómo se usa en el marketing esta data? La inteligencia artificial realiza los procesos de recopilación y preparación de datos con técnicas avanzadas de aprendizaje automático. Primero, automatiza la recopilación de datos en tiempo real con herramientas como *trackers web* y *cookies*, que monitorizan las interacciones de los usuarios en la plataforma (Han *et al.*, 2011). Luego aplica algoritmos de preprocesamiento para depurar y transformar los datos, como la eliminación de duplicados y la imputación de datos faltantes (Kotsiantis *et al.*, 2006); con métodos de análisis exploratorio, la inteligencia artificial identifica patrones y correlaciones en los datos, como las preferencias de los productos o el comportamiento de compras y esta acción es la que permite entrenar modelos predictivos que generan las recomendaciones personalizadas de manera continua, que se adaptan según las preferencias individuales del consumidor.

Es más sencillo comprenderlo si se aplica a una tienda en línea que quiere mejorar su estrategia utilizando algoritmos de aprendizaje automático para ofrecer recomendaciones personalizadas a sus clientes, aumentar la tasa de conversión y el nivel de satisfacción. Se busca que la inteligencia artificial extraiga las preferencias individuales en tiempo real, y esto empieza cuando los especialistas en marketing buscan los datos de sus usuarios utilizando anuncios en redes sociales y motores de búsqueda para atraer a los clientes a un sitio. Cada vez que un usuario hace clic en el enunciado, se registra la información con el tipo de producto promocionado, la hora del clic y la página de destino. Así se rastrean los anuncios más efectivos para diferentes segmentos usando

IA. Cuando un cliente navega por el sitio web de la tienda, su recorrido se monitorea en tiempo real (páginas de productos visitados, tiempo en cada página, interacciones con las imágenes de productos como al hacer zoom o ver las opciones de color) y de esta forma se infiere el interés específico en ese producto (Jaby, 2024).

Las compras anteriores ofrecen muchos datos sobre las preferencias de estilo; si un cliente compra varias corbatas de seda, es probable que prefiera materiales similares en futuras recomendaciones. Luego de realizar una compra, una tienda en línea invita a los clientes a valorar los productos y dejar comentarios; estos son datos cualitativos para identificar qué productos gustan y por qué (como al evaluar con la mayor puntuación una prenda de vestir para el frío extremo, lo que ayuda a segmentar a los clientes con base en el clima de su región) (Jaby, 2024).

Se presenta una etapa de preprocesamiento, donde los datos deben ser depurados y normalizados para asegurar que tengan calidad y coherencia, eliminando duplicados, manejando datos faltantes y transformando las variables categóricas en formatos adecuados para los modelos, como sucede con la codificación *one-hot* (Kotsiantis *et al.*, 2006). La IA se asegura de que cada entrada de datos sea única y evita sesgos en el análisis, porque la eliminación de duplicados puede reducir la redundancia en un 20-30% en *datasets* grandes (Han *et al.*, 2011). Si un usuario recarga varias veces la página de un producto, su comportamiento genera entradas duplicadas en el historial de navegación, por lo que la tienda debe utilizar algoritmos para eliminar estos duplicados y que cada interacción se cuente solo una vez.

Para el manejo de datos faltantes, los métodos comunes incluyen la imputación de datos o la eliminación de registros incompletos; al imputar datos faltantes se mejora la calidad del modelo en hasta un 15% (Kotsiantis *et al.*, 2006). Es decir, cuando algunos clientes pueden omitir los comentarios o no completan el perfil; la IA aplica técnicas de imputación, como el promedio de valoraciones de productos similares y con esos datos rellena esos espacios vacíos sin introducir sesgos (Mehrabi *et al.*, 2022). Luego viene una etapa de transformación de variables categóricas. La codificación *one-hot* convierte

las variables categóricas en un formato binario que los algoritmos pueden procesar con más facilidad, y es una técnica que ha demostrado mejorar la precisión del modelo en un 10% a 20% en algunos estudios (Han *et al.*, 2011). Una tienda de ropa que maneja datos categóricos como colores o tallas mediante esta codificación crea una variable binaria que indica la preferencia de un cliente que prefiera pantalones de color verde, permitiendo al algoritmo de recomendación identificar el patrón de los colores favoritos.

El siguiente paso es el análisis exploratorio de datos (EDA), que se realiza para identificar patrones y características importantes en los datos que ayuden a comprender mejor el comportamiento del consumidor y a definir qué variables son relevantes para la personalización. Se realiza en pasos que incluyen la visualización de datos, donde se utilizan gráficos como histogramas, diagramas de dispersión y mapas de calor para identificar patrones, tal como el estudio de Alimkhodjaeva (2022) que sirve como antecedente para demostrar que las visualizaciones pueden mejorar la comprensión de los datos en un 30%. Desde la perspectiva del marketing, la tienda de ropa realiza un análisis exploratorio de datos para descubrir patrones como los relacionados con la visualización de preferencias de color: un análisis de compras revelaría que el 40% de los clientes que compran en la temporada de invierno prefieren colores oscuros como el negro o el gris y visualiza estos datos en un gráfico de barras que ayuda a la tienda a ajustar sus recomendaciones según la estación.

El análisis de correlación examina las correlaciones entre variables para entender sus relaciones; las matrices pueden identificar las variables redundantes y relaciones significativas que afectan la personalización (Chambers, 2018). Esto quiere decir que al analizar la correlación entre el tiempo que un cliente se la pasa viendo un producto y la probabilidad de compra, la tienda descubre que los clientes que están más de 3 minutos en su página tienen un 50% más de probabilidades de realizar una compra y esta información hace que se prioricen las recomendaciones de productos similares para estos clientes. Finalmente, la identificación de *outliers* sirve para detectar valores atípicos que pueden distorsionar el análisis; según Iglewicz & Hoaglin (1993), esta detección puede

mejorar la precisión del modelo en hasta un 25%. Si la tienda detecta que un grupo mínimo de clientes compra productos de lujo, pero nunca deja una valoración, descubre que estos clientes valoran la exclusividad y prefieren mantener el perfil bajo, señalando la necesidad de ofrecerles una estrategia de marketing más personalizada para este segmento de compradores.

2) Selección e implementación de algoritmos. Con el filtrado colaborativo (que es el primer paso de la segunda etapa) se hacen recomendaciones basadas en las preferencias y comportamientos de los usuarios que tienen similitudes (Verhoef *et al.*, 2016). Los tipos de filtrado que se pueden usar serían el 'filtrado colaborativo basado en el usuario', que se centra en las recomendaciones basadas en los usuarios que tienen comportamientos similares, y el 'basado en ítem', con recomendaciones basadas en la similitud entre los productos o servicios ofrecidos (Su & Khoshgoftaar, 2019). Luego se implementan modelos que recomienden productos o servicios en función de las características del ítem y las preferencias explícitas del usuario; son modelos que pueden usar técnicas de análisis de texto y análisis semántico para extraer las características más relevantes. Se combina el filtrado colaborativo y los modelos basados en contenido para mejorar la precisión de las recomendaciones, de acuerdo con Su & Khoshgoftaar (2019); los modelos híbridos mitigan las debilidades de los enfoques individuales y proporcionan recomendaciones más precisas y objetivas (Burke, 2002). De allí, se cierra con el uso de las redes neuronales, como las RNN o las CNN (redes neuronales recurrentes y redes neuronales convolucionales), para captar patrones complejos en grandes volúmenes de datos y mejorar la capacidad predictiva del sistema de recomendación (Zhang *et al.*, 2019).

La selección e implementación de algoritmos en marketing utilizando inteligencia artificial debe elegir los modelos más adecuados para analizar y predecir el comportamiento del consumidor, mejorando las estrategias de personalización. Se usan algoritmos de filtrado colaborativo y redes neuronales, porque el primero analiza los patrones de comportamiento similares entre los usuarios que tienen perfiles diferentes para

recomendar productos que les hayan gustado a consumidores con perfiles parecidos (Aggarwal, 2016). Las redes neuronales profundas, como los modelos de recurrencia LSTM pueden predecir tendencias a futuro analizando las secuencias temporales de interacciones de los usuarios con los productos (Zhang *et al.*, 2019). En una tienda en línea, un algoritmo de filtrado colaborativo recomendaría a un cliente productos que han comprado otros con gustos similares y, a la vez una red neuronal LSTM puede predecir cuándo es más probable que un cliente haga una compra basada en su historial de navegación y compras previas, ajustando las recomendaciones en tiempo real para aumentar la probabilidad de conversión (Goodfellow *et al.*, 2016).

3) Evaluación y mejoramiento de modelos. En esta etapa se emplean métricas como *precision*, *recall* y *F1-score* para evaluar la efectividad de los algoritmos, pero también considera métricas específicas de recomendación, como las tasas de clics (CTR), la tasa de conversión y el índice de satisfacción del usuario. Culminado este paso, se implementan técnicas de validación cruzada para asegurarse de que los modelos generalicen bien los datos no vistos y evitar el sobreajuste; utiliza particiones de datos para entrenar y probar los modelos en diferentes subconjuntos de datos (Bergstra & Bengio, 2012). Como último paso de esta etapa, se realizan ajustes de hiperparámetros (Bergstra & Bengio, 2012) para mejorar el rendimiento del modelo y técnicas como la búsqueda en cuadrícula (*grid search*) o la optimización bayesiana para encontrar los parámetros óptimos (Ricci *et al.*, 2015).

El uso del marketing con inteligencia artificial mide en esta etapa el rendimiento de los algoritmos y los optimiza continuamente para mejorar la precisión de las recomendaciones y otras estrategias personalizadas. Una de las técnicas que utilizan los especialistas son las métricas de evaluación, como la precisión y recuperación (*precisión and recall*), para determinar qué tan efectivas son las recomendaciones generadas por un modelo (Powers, 2011). En un 'escenario' de marketing, se puede utilizar un conjunto de datos de prueba para evaluar cuántas recomendaciones de productos son realmente relevantes para el usuario. Si el modelo no alcanza el rendimiento deseado, se pueden

ajustar los hiperparámetros, añadir más datos de entrenamiento o cambiar a un algoritmo más avanzado, como una red neuronal convolucional para mejorar la capacidad predictiva (Zhang *et al.*, 2019). Este es un proceso continuo que mejora el modelo; con técnicas como el aprendizaje por refuerzo, se puede adaptar a las preferencias de los usuarios, mejorando su rendimiento con el tiempo basado en la alimentación continua real de las interacciones de los clientes (Sutton & Barto, 2018).

4) Implementación y monitoreo en tiempo real. La integración en el sistema de marketing se asegura de que los algoritmos se integren como debe ser en el sistema de marketing de la empresa, y debe permitir la actualización continua de recomendaciones basadas en nuevos datos de comportamiento del usuario. El segundo paso es el monitoreo y los ajustes; se implementan mecanismos para el monitoreo continuo del rendimiento del sistema de recomendación y se realizan los ajustes periódicos en los algoritmos para adaptarse a los cambios en el comportamiento del consumidor y en el entorno del mercado (Jabbar *et al.*, 2020).

La explicación más sencilla supone que se desplieguen algoritmos que puedan adaptar y mejorar las estrategias de personalización basadas en las interacciones del usuario en tiempo real. Por ejemplo, las redes neuronales recurrentes (RNNs) y los modelos de decisión en línea pueden ser implementados para analizar continuamente el comportamiento de los consumidores mientras navegan en un sitio web, ajustando las recomendaciones de productos instantáneamente (Goodfellow *et al.*, 2016). Estos son modelos que procesan datos secuenciales como los clics y tiempo en página para actualizar sus predicciones a medida que reciben nueva información, para crear una personalización activa.

El monitoreo en tiempo real es facilitado por sistemas de *streaming* de datos como Apache Kafka, que permite capturar, procesar y analizar grandes volúmenes de datos de usuarios en milisegundos (Kreps, 2014). Si un cliente muestra interés repentinamente en una categoría específica de productos, la inteligencia artificial puede ajustar las

ofertas promocionales en tiempo real para captar ese interés, aumentando las probabilidades de conversión.

5) Consideraciones éticas y de privacidad. En esta última etapa, con al protección de datos se asegura que la recopilación y el uso de datos cumplan con las regulaciones de privacidad (Hoofnagle *et al.*, 2019). La transparencia y consentimiento también proporcionan al consumidor información clara sobre cómo se utilizan sus datos para la personalización y obtener su consentimiento informado para la recopilación y uso (Solove, 2010). Finalmente, se implementan mecanismos para identificar y mitigar sesgos en los algoritmos de recomendación, asegurando que las recomendaciones sean justas y equitativas para todos los usuarios. Voight & Von dem Bussche (2017) explican que con inteligencia artificial se recopilan y analizan datos personales, pero se debe cumplir con las regulaciones establecidas para la protección de datos, como en la Unión Europea que existe el Reglamento General de Protección de Datos (Hoofnagle *et al.*, 2019), que exige el consentimiento del usuario para recopilar y usar sus datos.

Una plataforma de comercio electrónico que utilice inteligencia artificial para personalizar ofertas tiene que asegurarse de que sus usuarios hayan consentido primero el seguimiento de su actividad en línea, los datos deben ser anónimos para evitar la identificación de las personas y reducir el riesgo a las violaciones de privacidad (Dwork & Roth, 2014; Solove, 2010). Las empresas también deben ser claras sobre cómo se usarán sus datos y darle control a los usuarios sobre las preferencias de privacidad. Con esto se asegura el uso de la inteligencia artificial de manera ética, igual que cuando se evita el sesgo algorítmico (que puede discriminar), asegurando que las recomendaciones y ofertas sean equitativas para todos los usuarios (Friedman & Nisseanbaum, 1996).

Conclusión

Las conclusiones de este estudio destacan la capacidad transformadora de la inteligencia artificial en la personalización del marketing, destacando la importancia de implementarla de manera cuidadosa y con ética. Los algoritmos de aprendizaje automático ofrecen un potencial significativo para mejorar la experiencia del usuario, aumentar la tasa de conversión y mejorar la satisfacción del cliente. A través de la recopilación y preparación de datos en tiempo real, la selección y ajuste continuo de modelos, y la implementación dinámica, los profesionales del marketing pueden ofrecer recomendaciones que son personalizadas y responden a las preferencias de los distintos segmentos de consumidores. Sin embargo, esto se acompaña de la necesidad de abordar los principios éticos y de privacidad para que los datos sean utilizados de manera responsable.

La combinación de técnicas avanzadas con un enfoque centrado en el usuario mejora la eficacia del marketing personalizado, promoviendo una relación de confianza entre las marcas y los consumidores. Se puede hablar de éxito cuando se mantiene un equilibrio entre la tecnología y la ética, para que todos los beneficios que provengan de la personalización no se alcancen a costa de la privacidad del usuario. Por eso se recomienda mantener un monitoreo y ajuste constante, junto con el mantenimiento de las normativas de privacidad para que las empresas puedan capitalizar el poder que tiene la inteligencia artificial, mientras se fortalece la confianza del consumidor.

Referencias Bibliográficas

- Aggarwal, C. C. (2016). *Recommender systems* (Vol. 1). Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-29659-3>
- Alimkhodjaeva, N. (2022). A systematic mapping study of using artificial intelligence and data analysis in digital marketing: Revealing the state of the art. In *Proceedings of the 6th International Conference on Future Networks & Distributed Systems*, 116-120. <https://doi.org/10.1145/3584202.3584220>
- Balcázar Nava, P., González-Arratia López-Fuentes, N. I., Gurrola Peña, G. M., & Moysén Chimal, A. (2013). *Investigación cualitativa*. UAEM.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2). <https://acortar.link/ETWup7>
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 12, 331-370. <https://acortar.link/DOWrAG>
- Chambers, J. M. (2018). *Graphical methods for data analysis*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781351072304>
- Chase, S.E. (2015). Investigación narrativa. En Denzin, N. K., & Lincoln, Y. (2015). *Métodos de recolección y análisis de datos. Manual de investigación cualitativa. IV*, 58-112.
- Goodfellow, I. (2016). *Deep learning* (Vol. 196). MIT Press.
- Han, J., Kamber, M., & Pei, J. (2011). The Morgan Kaufmann series in data management systems. *Data mining concepts and techniques*, 5(4), 83-124. <https://acortar.link/dU3RYw>
- Hoofnagle, C. J., Van Der Sloot, B., & Borgesius, F. Z. (2019). The European Union general data protection regulation: what it is and what it means. *Information & Communications Technology Law*, 28(1), 65-98. <https://doi.org/10.1080/13600834.2019.1573501>
- Iglewicz, B. & Hoaglin, D.C. (1993). *How to Detect and Handle Outliers*. ASQC.
- Jabbar, A., Akhtar, P., & Dani, S. (2020). Real-time big data processing for instantaneous marketing decisions: A problematization approach. *Industrial Marketing Management*, 90, 558-569. <https://doi.org/10.1016/j.indmarman.2019.09.001>
- Jaby, K.J. (2024). 10 Excellent Ways AI will Improve Customer Experience in 2024. In *Survey Sparrow*. <https://surveysparrow.com/blog/ai-customer-experience/>

- Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). Data preprocessing for supervised learning. *International Journal of Computer Science*, 1(2), 111-117. <https://acortar.link/2wcl07>
- Martínez Miguélez, M. (2006). Validez y confiabilidad en la metodología cualitativa. *Paradigma*, 27(2), 07-33.
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2022). A survey on bias and fairness in machine learning. *ACM computing surveys (CSUR)*, 54(6), 1-35. <https://arxiv.org/pdf/1908.09635>
- Mirjalili, V., & Raschka, S. (2020). *Python machine learning*. Marcombo.
- Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender Systems Handbook*. Springer.
- Rojas Rojas, D. S., & Diaz Cadena, N. V. (2023). *Guía para la personalización del marketing: cómo aumentar la lealtad del cliente en una organización*. (Monografía). Universidad Santo Tomás.
- Rollins, A. & Amato, D. (2024). How Will AI Impact Marketing Metrics? In *Attentive*. <https://www.attentive.com/blog/impact-of-ai-on-marketing-metrics>
- Solove, D. J. (2010). *Understanding privacy*. Harvard University Press.
- Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in artificial intelligence*, 2009(1), 421425. Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in artificial intelligence*, 2009(1), 1-19. doi:10.1155/2009/421425
- Verhoef, P. C., Kooge, E., & Walk, N. (2016). *Creating value with big data analytics: Making smarter marketing decisions*. Routledge.
- Zhang, S., Yao, L., Sun, A. & Tay, Y. (2018). Deep Learning based Recommender System: A Survey and New Perspectives. *ACM Computing Survey*, 1(1), 1-35.