



Universidad Pontificia de Comillas - ICADE
Grado en Administración y Dirección de Empresas

EL IMPACTO DE LOS SISTEMAS DE RECOMENDACIÓN EN LOS CONSUMIDORES: EL CASO DE AMAZON

Autor: Irene María Castaño Martínez

Director: María Olga Bocigas Solar

MADRID | Diciembre, 2024

RESUMEN

El presente trabajo analiza el impacto de los sistemas de recomendación, basados en algoritmos de Aprendizaje Automático, en los consumidores de los *marketplaces* B2C, tomando como caso de estudio a Amazon. Partiendo del marco teórico que aborda las características, tipos y modelo de negocio de los *marketplaces*, se estudia su evolución como canales de distribución que ofrecen funcionalidades y ventajas adicionales a los fabricantes que operan en ellos. La definición de los conceptos fundamentales del Aprendizaje Automático permite profundizar en el funcionamiento de los sistemas de recomendación como herramientas clave en la personalización de la experiencia de compra, detallando los tres tipos principales: filtrado colaborativo, filtrado basado en contenido y sistemas híbridos. Además, se evalúan teóricamente sus efectos en el comportamiento del consumidor, como la satisfacción y la toma de decisiones. La validación de las observaciones teóricas se realiza a través de un estudio empírico en forma de cuestionario *online* dirigido a los consumidores de Amazon, en el que se investigan las percepciones sobre la utilidad, relevancia y efectividad de las recomendaciones personalizadas. Por último, el trabajo sugiere estrategias e iniciativas adicionales con el fin de optimizar las recomendaciones actuales de la empresa, destacando su importancia para atraer y retener a los consumidores.

Palabras Clave

Marketplaces, Sistemas de Recomendación, Aprendizaje Automático, Algoritmos, Personalización, Comercio Electrónico, Experiencia del Consumidor, Amazon, Estrategias

ABSTRACT

This study analyzes the impact of recommendation systems based on Machine Learning algorithms on B2C marketplace consumers, using Amazon as a case study. Starting from a theoretical framework that examines the characteristics, types, and business model of marketplaces, the research explores their evolution as distribution channels offering additional functionalities and advantages to manufacturers operating within them. The definition of fundamental Machine Learning concepts enables a deeper understanding of the functioning of recommendation systems as key tools for personalizing the shopping experience, detailing the three main types: collaborative filtering, content-based filtering, and hybrid systems. Additionally, their effects on consumer behavior, such as satisfaction and decision-making, are theoretically evaluated. The validation of these theoretical observations is carried out through an empirical study in the form of an online questionnaire directed at Amazon consumers, investigating perceptions regarding the utility, relevance, and effectiveness of personalized recommendations. Finally, the project suggests additional strategies and initiatives aimed at optimizing the company's current recommendations, highlighting their importance in attracting and retaining consumers.

Keywords

Marketplaces, Recommendation Systems, Machine Learning, Algorithms, Personalization, E-commerce, Consumer Experience, Amazon, Strategies

Índice

CAPÍTULO I: Introducción	1
1.1. Motivación	1
1.2. Objetivos	2
1.3. Metodología	2
1.4. Estructura	3
CAPÍTULO II: Los <i>Marketplaces</i> B2C	5
2.1. Concepto y Modelo de Negocio.....	5
2.2. Características de los <i>Marketplaces</i>	8
2.3. Tipos de <i>Marketplaces</i>	9
2.4. Impacto de los <i>Marketplaces</i> para los Fabricantes	10
2.5. Ventajas e Inconvenientes de los <i>Marketplaces</i>	12
2.6. Historia y Evolución de los <i>Marketplaces</i>	15
CAPÍTULO III: Los Sistemas de Recomendación	18
3.1. El <i>Machine Learning</i> y los Sistemas de Recomendación	18
3.2. El <i>Machine Learning</i> en Marketing	20
3.3. Sistemas de Recomendación: Concepto y Características	24
3.4. Funcionamiento y Tipos de Sistemas de Recomendación	28
3.4.1. <i>Filtrado Colaborativo</i>	29
3.4.2. <i>Filtrado por Contenido</i>	31
3.4.3. <i>Sistemas Híbridos</i>	32
3.5. Desafíos y Áreas de Investigación	33
3.6. Impacto en el Comportamiento del Consumidor	35
CAPÍTULO IV: El Caso de Amazon	39
4.1. Contextualización del Caso de Estudio.....	39
4.2. Las Estrategias de Personalización de Amazon.....	41
4.3. Estudio sobre las Percepciones de los Consumidores de Amazon sobre sus Sistemas de Recomendación	45
4.4. Análisis de Resultados	46
4.5. Oportunidades y Áreas de Mejora	51
CAPÍTULO V: Conclusiones y Desarrollos Futuros.....	55
5.1. Conclusiones	55
5.2. Limitaciones y Desarrollos Futuros	57

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado	59
CAPÍTULO VI: Bibliografía	61
ANEXO I: Cuestionario	72
ANEXO II: Resultados del Cuestionario	78

Índice de Figuras

Figura 1: Funcionamiento de un marketplace B2C.....	6
Figura 2: Fuentes de ingreso de algunos de los marketplaces más conocidos.	7
Figura 3: Beneficios del marketplace para el fabricante.	13
Figura 4: Marketplaces B2C más populares por continentes.	16
Figura 5: Aplicación de los algoritmos de Machine Learning cada una de las variables de decisión de marketing.....	22
Figura 6: Tendencias en el nuevo ecosistema de Marketing impulsadas por la IA y el ML.....	23
Figura 7: Funcionamiento general de un sistema de recomendación.	29
Figura 8: Funcionamiento de un sistema de recomendación por filtrado colaborativo basado en usuarios.	30
Figura 9: Funcionamiento de un sistema de recomendación por filtrado colaborativo basado en artículos.....	30
Figura 10: Modelos de implementación de los sistemas de recomendación híbridos.	33
Figura 11: Ranking de marketplaces online con mayor tasa de penetración entre los consumidores en España en 2023.....	40
Figura 12: Frecuencia con la que los consumidores de Amazon encuestados consideran cada uno de los tipos de recomendación antes de efectuar una compra.....	47
Figura 13: Percepción que los consumidores de Amazon encuestados tienen de la relevancia de cada uno de los distintos tipos de recomendación.	48
Figura 14: Beneficios que destacan los consumidores encuestados de las recomendaciones que les ofrece Amazon.....	49
Figura 15: Experiencias que destacan los consumidores de Amazon encuestados respecto a las recomendaciones.	51
Figura 16: Oportunidades e iniciativas de mejora de las recomendaciones actuales de Amazon.	52

CAPÍTULO I: Introducción

El *Capítulo I* abarca el marco teórico introductorio en el que se presenta la motivación que justifica la elección del tema del trabajo, los objetivos que se persiguen con el trabajo, la metodología seguida y la estructura final de la documento.

1.1. Motivación

En la era digital, el auge de las compras *online* ha transformado la manera en que los consumidores adquieren bienes y servicios. En este contexto, surgen los *marketplaces* B2C como una opción útil y eficiente, brindando a los consumidores acceso a miles de productos dentro de una misma plataforma, ofreciendo a los fabricantes ventajas a la hora de comercializar sus productos y consolidándose como el modelo de negocio líder en el entorno virtual.

No obstante, la infinidad de la oferta en el *marketplace* supone un nuevo reto: “la infoxicación”, también conocida como la sobrecarga de información a la que deben hacer frente los consumidores y que puede dificultar su toma de decisiones. Esta situación, a veces algo abrumadora, se alivia con la presencia de sistemas de recomendación. Los sistemas de recomendación se basan en algoritmos de Aprendizaje Automático (o *Machine Learning*) y minimizan el impacto de la “infoxicación”, facilitando la experiencia de compra del usuario, adaptándola y personalizándola para ayudarles a encontrar los productos que mejor se ajustan a sus necesidades e intereses. En un mundo que va cada vez más deprisa, y donde el tiempo es un recurso limitado, los sistemas de recomendación se han vuelto indispensables a la hora de optimizar la navegación del usuario en los *marketplaces* y acelerar el proceso de compra.

Este trabajo nace de la necesidad de entender cómo estos sistemas influyen en el comportamiento del consumidor, y cuáles son las oportunidades y ventajas que les ofrecen y que los hacen tan especiales. Así pues, resulta también vital comprender cómo funcionan y cómo se integran en las plataformas, para mejorar la experiencia del cliente y mejorar el posicionamiento de los fabricantes. Estudiar el caso de Amazon, como empresa referente en comercio electrónico, permite obtener una idea de la magnitud de estas tecnologías, comprender la relevancia que tienen las recomendaciones para el consumidor e identificar oportunidades para mejorar aún más si cabe su experiencia, evaluando las nuevas tendencias de consumo en el entorno digital actual.

1.2. Objetivos

El objetivo principal del presente trabajo consiste en analizar el impacto de los sistemas de recomendación, basados en algoritmos de *Machine Learning*, sobre los consumidores de *marketplaces* de tipo B2C, estudiando en particular el caso de Amazon. Para ello:

- Se estudiarán las aplicaciones del *Machine Learning* en los *marketplaces* B2C en el contexto del Marketing, centrándose en los sistemas de recomendación.
- Se examinarán las consecuencias que tiene la aplicación de los sistemas de recomendación en la experiencia de compra del cliente, a partir de una revisión teórica y un análisis exploratorio utilizando el caso de estudio de Amazon.
- Se identificarán las oportunidades y áreas de mejora en las estrategias de personalización de Amazon, basándose en los resultados empíricos obtenidos de sus consumidores.

Además, el trabajo estará alineado con los Objetivos de Desarrollo Sostenible (ODS), cumpliendo especialmente con el objetivo n.º 9 “*Industria, Innovación e Infraestructura*”.

1.3. Metodología

La metodología del trabajo abarca un enfoque mixto que combinará tanto la revisión de la literatura académica, como la investigación empírica a través de una encuesta.

La revisión exhaustiva de la literatura existente permitirá desarrollar un marco teórico que comprenda los conceptos básicos de los que trata el trabajo. Para ello, se procederá a la recopilación de *papers* académicos de bases de datos como Dialnet, Google Scholar, Research Gate, el repositorio de la Universidad Pontificia de Comillas y otros artículos que provee la biblioteca online de Macquarie University. Las búsquedas en tales plataformas se llevarán a cabo empleando *keywords* como: “*Machine Learning*”, “*E-commerce*”, “*Recommender Systems*”, “*Amazon*”, “*Online Customer Experience*”, entre otros.

Por su parte, la investigación se centrará en el caso de Amazon, contextualizando el supuesto de estudio mediante la revisión de fuentes secundarias y artículos *online*, e investigando en la medida de lo posible cómo aplica la plataforma estos sistemas de recomendación. El principal objetivo

de la investigación es averiguar las percepciones que tienen los consumidores de Amazon sobre las recomendaciones que se les presentan en la plataforma.

Para recopilar los datos, se empleó la técnica de encuesta mediante cuestionario, ampliamente utilizada en investigación de mercados, ya que facilita obtener respuestas estandarizadas y procesarlas posteriormente (Bryman, 2016). En este caso, la encuesta se diseñó como un cuestionario *online* autoadministrado en Google Forms, que permitió alcanzar un gran número de individuos de forma eficiente y económica (Etikan et al., 2016; Saunders et al., 2019), mitigando el sesgo que introduce la presencia del investigador (Bryman, 2016).

Por su parte, la población objetivo estuvo constituida por aquellos consumidores de Amazon situados en España y seleccionados a través de muestreo no probabilístico por conveniencia, además de muestreo por bola de nieve, expandiendo el alcance del estudio (Saunders et al., 2019).

Tras su difusión en WhatsApp se obtuvieron un total de 121 respuestas, de las cuales sólo 105 eran válidas por cumplir con los requisitos impuestos a la población objetivo. Los datos recopilados fueron tratados en Excel, representando gráficamente los resultados. No obstante, los detalles específicos sobre la metodología aplicada se pueden consultar en el *Epígrafe 4.3*.

1.4. Estructura

El trabajo se estructura en torno a cinco capítulos principales y dos anexos. El **Capítulo I**, correspondiente a la “**Introducción**” del trabajo, presenta la motivación y justificación del tema, los objetivos perseguidos, la metodología empleada para su desarrollo y la estructura que sigue el presente documento.

Una vez se ha obtenido la visión general del contenido, el **Capítulo II “Los Marketplaces B2C”** aborda el concepto y la realidad de los *marketplaces*, centrándose en el modelo B2C como canal de distribución. En este capítulo, se exponen los distintos tipos de marketplaces que existen, detallando sus características y fuentes de ingreso. Asimismo, se comenta el impacto que estas plataformas tienen sobre los fabricantes, estudiando las ventajas e inconvenientes, para concluir con un análisis de su evolución en el contexto de la era digital y la globalización.

A continuación, en el **Capítulo III “Los Sistemas de Recomendación”** se introducen las nociones básicas sobre *Machine Learning* como base de los sistemas de recomendación, explicando su funcionamiento y sus aplicaciones en Marketing. A partir de esta introducción, se

profundiza en el concepto de sistema de recomendación, identificando sus tipos principales, los datos empleados para generar las recomendaciones y el impacto que tienen éstas sobre el comportamiento del consumidor mediante la revisión de la literatura académica.

Posteriormente, el **Capítulo IV “El Caso de Amazon”** constituye el caso estudio del trabajo, donde tras una breve introducción sobre la empresa, se abarcarán las estrategias de personalización y sistemas de recomendación implementados por Amazon. Este capítulo incluye el diseño del cuestionario utilizado para la investigación empírica, el análisis de los resultados obtenidos, y una propuesta de oportunidades de crecimiento, así como áreas de mejora para la empresa.

Por último, el **Capítulo V “Conclusiones y Desarrollos Futuros”** se centra en sintetizar las conclusiones esenciales del trabajo, conectando los hallazgos empíricos con la teoría desarrollada anteriormente. Este capítulo establece la relación teórico-práctica del impacto de los sistemas de recomendación en los consumidores de Amazon, verificando la consecución de los objetivos del trabajo planteados en la introducción. Asimismo, se discuten las limitaciones del trabajo y se plantean futuras líneas de investigación que podrían ampliar el alcance del mismo.

Finalmente, el documento incluye la **Bibliografía** del trabajo en el **Capítulo VI**, y se complementa con los **Anexos I y II “Cuestionario”** y **“Resultados del Cuestionario”**, que contienen el cuestionario completo distribuido, y los resultados obtenidos, respectivamente.

CAPÍTULO II: Los *Marketplaces* B2C

En este capítulo se presentan las nociones esenciales que permiten definir el concepto y la realidad de los fabricantes que utilizan los *marketplaces* B2C como canales de distribución, lo que constituye el eje central del presente trabajo.

A continuación, se analizarán los modelos de negocio de *marketplace* existentes y se detallarán las características y funciones que distinguen a estas plataformas. Asimismo, se examinarán tanto las ventajas como los inconvenientes que plantea la relación entre los fabricantes y los *marketplaces*. Finalmente, se revisará el estado del arte de los *marketplaces* B2C, destacando los desafíos y tendencias actuales a los que se enfrentan los fabricantes en un entorno digital cada vez más competitivo.

2.1. Concepto y Modelo de Negocio

En la última década, los *marketplaces* han experimentado un notable crecimiento, consolidándose como plataformas que facilitan de manera eficiente la interacción entre vendedores y compradores, transformando el entorno digital en un espacio dinámico para las transacciones comerciales. Los *marketplaces* B2C (*Business-to-Consumer*), en particular, destacan por conectar de forma casi instantánea a fabricantes con consumidores finales, ofreciendo una experiencia de compra simplificada y conveniente. Estas plataformas proporcionan una infraestructura robusta que ha revolucionado la forma en que compramos en línea, permitiendo a los consumidores encontrar todo lo que necesitan en un solo lugar. La comodidad que ofrecen plataformas como Amazon o eBay ha supuesto cambios significativos en nuestra rutina de compra como consumidores, ahorrándonos tiempo y esfuerzo, pero ¿qué es realmente un *marketplace*?

Los *marketplaces* son plataformas digitales que actúan como canal de distribución, permitiendo a los fabricantes llegar a los consumidores sin necesidad de crear sus propios canales de venta directos. Además de facilitar la conexión con el consumidor final, plataformas como Amazon o Miravia proporcionan servicios adicionales que resultan de gran valor para los fabricantes, como la gestión de la logística, el almacenamiento y los sistemas de recomendación personalizados. Esto no solo permite a los fabricantes concentrarse en su producción, sino que también mejora la visibilidad y competitividad de sus productos en un entorno cada vez más digitalizado.

La *Figura 1* representa de forma gráfica el funcionamiento de un *marketplace B2C*:

Figura 1: Funcionamiento de un marketplace B2C.



Fuente: Shingala (2020)

No obstante, Tapia Arrate (2001) y Einav et al. (2016) establecen que los *marketplaces* pueden estar configurados bajo distintos **modelos de negocio** según los agentes involucrados en las transacciones:

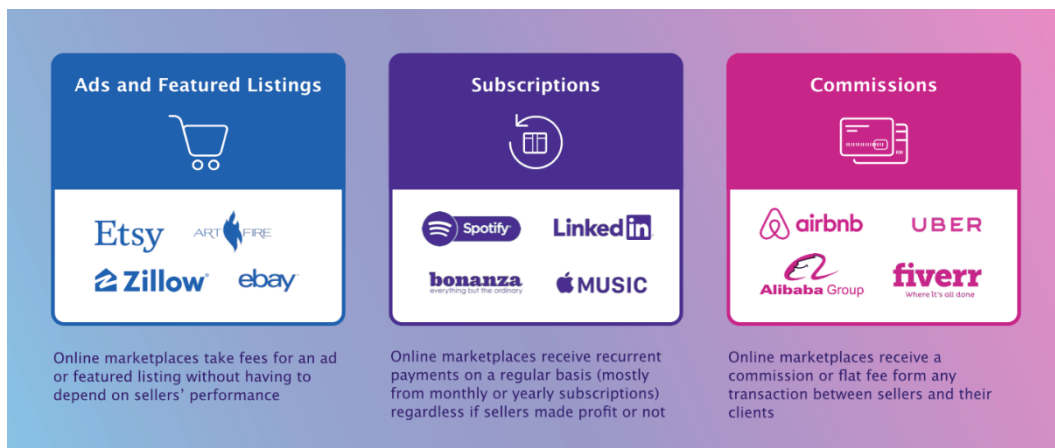
- B2B (*Business-to-Business*): para transacciones entre empresas. Por ejemplo: Alibaba.
- B2C (*Business-to-Consumer*): para venta de bienes de empresas a consumidores. Por ejemplo: Amazon o Miravia.
- P2P (*Peer-to-Peer*): para transacciones de individuos sin la intermediación de terceros. Por ejemplo: Airbnb.
- C2C (*Consumer-to-Consumer*): para transacciones entre consumidores. Por ejemplo: eBay o Etsy.
- C2B (*Consumer-to-Business*): para venta de bienes de consumidores a empresas. Por ejemplo: Upwork.
- B2G (*Business-to-Government*): para venta de bienes de empresas a organismos gubernamentales. Por ejemplo: GSA Advantage en Estados Unidos.

Cabe entonces puntualizar que en el presente trabajo nos enfocaremos principalmente en el **modelo B2C**, donde los fabricantes utilizan los *marketplaces* como canales de distribución para vender directamente a los consumidores finales. Por ello, de aquí en adelante, el término *marketplace* hará referencia exclusivamente a este modelo, clave para entender cómo los fabricantes utilizan estas plataformas para beneficiarse de los servicios adicionales que ofrecen.

Así pues, Corrot & Nussenbaum (2023) sostienen que el beneficio económico de los *marketplaces* proviene de las siguientes **fuentes de ingreso**, tal y como se recoge en la *Figura 2*:

- Comisiones que cobra de los fabricantes con cada transacción realizada. En el caso de Amazon esta cifra oscila entre el 6% y el 45% del precio de venta, dependiendo de la categoría del producto (Padeco Global, 2023).
- Planes de suscripción que ofrece tanto a clientes como a fabricantes. Por ejemplo, Amazon (s.f.) detalla que la suscripción a Amazon Prime para clientes es de 49,90€ al año o 4,99€ al mes, mientras que el Plan Profesional para fabricantes es de 39€ al mes.
- Servicios publicitarios que facilita a los fabricantes para mejorar la visibilidad y el posicionamiento de los productos. Se dice que tan sólo en 2021 Amazon cobraría 31.200 millones de dólares por sus servicios publicitarios (Lacort, 2022).
- Prestaciones de logística, como almacenamiento o envío de productos. En el caso de Amazon, los fabricantes de productos de moda en España habrían de pagar 16,52€/mes de enero a septiembre y 23,11€/mes de octubre a diciembre por el almacenamiento de productos de tamaño estándar (Amazon, 2024).
- Venta de datos a terceros interesados en realizar análisis de mercado. En Europa central, Amazon cobraría 0,04167\$ por cada hora activa de concesión de datos (AWS, s.f.).

Figura 2: Fuentes de ingreso de algunos de los marketplaces más conocidos.



Fuente: ListLink (2024)

2.2. Características de los *Marketplaces*

A continuación, se exponen algunas de las características más significativas que definen a los *marketplaces*:

- **Intermediarios multilaterales:** los *marketplaces* B2C conectan multitud de fabricantes (la oferta) con multitud de compradores (la demanda) en una única plataforma, gestionando y permitiendo el intercambio de información sobre productos y precios entre ambas partes (Maier & Wieringa, 2021). En este sentido, se asemejan a un gran centro comercial digital donde diversas empresas pueden exponer y vender sus productos al consumidor final (Santander Impulsa Empresa, s.f.). Además, Tiwana (2014) afirma que son los responsables de establecer las normas y estándares por las que se rige la plataforma y de exigir su cumplimiento a todos sus usuarios.
- **Oferta amplia de productos y servicios:** la presencia de múltiples fabricantes hace que la oferta de estos *marketplaces* se vea disparada, resultando en una mayor variedad de alternativas para los consumidores en cuanto a precios, calidad e innovación. Todo ello incentiva su uso para realizar las compras del día a día.
- **Alta competencia entre fabricantes:** el *marketplace* ayuda a los fabricantes a ajustar sus precios de manera estratégica con el fin de atraer compradores, elaborar el perfil de cliente y adaptar las recomendaciones personalizadas para cada uno de ellos con ayuda de Inteligencia Artificial (IA). Tanto es así que Zhou & Zou (2023) determinan que el nivel de competencia dentro del *marketplace* viene mayoritariamente marcado por los intentos de posicionar mejor el producto y por el perfil del cliente objetivo.
- **Personalización de la oferta:** la implementación de herramientas de IA dentro de los *marketplaces* permite ajustar de manera personalizada la oferta a cada comprador en base las recomendaciones particulares que, a su vez, dependen de distintos factores como hábitos de compra, historial y búsquedas recientes en la web o datos demográficos (Kim et al., 2008). Este nivel de personalización no solo aumenta la visibilidad de los productos entre los consumidores, sino que también permite a los fabricantes dirigir campañas de marketing más efectivas basadas en perfiles de consumidor mucho más precisos (Van der Heijden, 2004).
- **Sistema de pago integrado:** los *marketplaces* cuentan con sistemas de pago avanzados que permiten efectuar transacciones *online* de manera rápida y segura gracias a herramientas de autenticación y detección de fraudes, proporcionando confianza tanto a

fabricantes como a consumidores. Además, según Rayport & Sviokla (1995) ofrecen múltiples métodos de pago, dotando al comprador de total libertad a la hora de elegir el que mejor le convenga.

- **Sistema de valoraciones y reseñas:** el diseño de la plataforma incluye sistemas de calificaciones y opiniones de los productos y servicios ofrecidos por los fabricantes, fomentando la fiabilidad de la información que ofrece cada fabricante, así como su reputación (Einav et al., 2016). Esta iniciativa es la que recoge la Teoría de la Señalización y juega un papel fundamental en el proceso de compra de los consumidores, pues permite trasladarles la calidad del producto percibida por otros compradores, influyendo directamente sobre la decisión final en un entorno digital que impide inspeccionar físicamente el bien en cuestión (Li et al., 2015).

2.3. Tipos de *Marketplaces*

Aparte de la clasificación de los *marketplaces* según el modelo de negocio, existe una clasificación alternativa atendiendo a la gestión de la plataforma y a la naturaleza de los bienes. Teniendo esto en cuenta, Tapia Arrate (2001) y Corrot & Nussenbaum (2023) dividen las plataformas en:

- **Horizontales:** ofrecen productos de distintos sectores y categorías, por lo que conectan a fabricantes de diversas industrias con los consumidores finales. De este modo, conceden acceso a los compradores a una gran variedad de productos bajo una misma interfaz. Un ejemplo de *marketplace* horizontal es Amazon, donde se pueden encontrar productos que van desde alimentos hasta electrónica y moda, facilitando a los fabricantes de diferentes sectores la distribución de sus bienes a través de un único canal.
- **Verticales:** ofrecen productos específicos de un sector, por lo que se centran en conectar a fabricantes y consumidores dentro de la misma industria. Por ello, son más especializados y proveen al público objetivo de experiencias más ajustadas. Un ejemplo de *marketplace* vertical es Zalando, que se enfoca exclusivamente en moda, calzado y accesorios, lo que permite a los fabricantes del sector textil optimizar su presencia en un canal altamente especializado.
- **Propios:** una empresa gestiona el *marketplace* y vende tanto sus propios productos como los de terceros fabricantes. La empresa propietaria controla la operación de la plataforma, pero permite la participación de otros fabricantes, siempre que cumplan con las

normativas establecidas. Un ejemplo de esto es Apple, que no solo vende sus propios productos como iPads o iPhones, sino también accesorios electrónicos de otros fabricantes como Logitech o Belkin.

- **Públicos:** se trata de plataformas abiertas que permiten a cualquier fabricante registrado llevar a cabo actividades comerciales, impulsando la competencia entre ellos. Un ejemplo es eBay, donde cualquier fabricante o empresa puede ofrecer sus productos a los consumidores siempre que se registre en la plataforma.
- **Privados:** se trata de plataformas cerradas que permiten participar a un grupo determinado de fabricantes previa aprobación, pues han de cumplir con estándares específicos de calidad. Un ejemplo es Farfetch, que solo permite la participación de boutiques de lujo cuidadosamente seleccionadas, lo que asegura un alto nivel de calidad y exclusividad en los productos ofrecidos.

2.4. Impacto de los *Marketplaces* para los Fabricantes

Los *marketplaces* B2C cumplen con varios propósitos más allá de facilitar únicamente interacciones entre la oferta y la demanda, mejorando la competitividad y eficiencia de los fabricantes que operan en ellos. Así pues, es preciso destacar los siguientes beneficios y funciones que ofrecen estos a los fabricantes:

- **Optimización de las recomendaciones:** los sistemas de recomendación ayudan a ordenar estratégicamente las sugerencias presentadas al consumidor de forma que maximicen el beneficio económico esperado tanto para el *marketplace*, como para el fabricante (Zhou & Zou, 2023). De esta manera, la mayor visibilidad del producto, junto con la mejora en su posicionamiento, se traduce en una optimización del rendimiento de ventas del fabricante (Li et al., 2015).
- **Captación de nuevos clientes:** los *marketplaces* proporcionan a los fabricantes acceso a una base de clientes potenciales a nivel global, gracias a la infraestructura de un mercado cada vez más digitalizado. Esta digitalización incrementa el alcance, la visibilidad y el potencial de ventas de los fabricantes. Maier & Wieringa (2021) estiman que el coste de adquisición de nuevos clientes figura en torno al 24% de las ventas generadas, por lo que ésta se convierte en una de las formas más económicas de atraer clientela en comparación con otros canales más tradicionales. De este modo, una menor inversión inicial permite el acceso a una base de clientes más amplia (Santander Impulsa Empresa, s.f.).

- **Complementación de los canales existentes:** los fabricantes que participan en *marketplaces* pueden diversificar sus canales de distribución. En algunos casos, los clientes captados a través del *marketplace* pueden ser redirigidos al sitio web oficial del fabricante, potenciando las ventas en otros canales propios. (Maier & Wieringa, 2021). Asimismo, permiten complementar las redes logísticas de los fabricantes ofreciéndoles servicios de transporte y almacenaje, y, por ende, simplificando la cadena de suministro (Santander Impulsa Empresa, s.f.).
- **Creación de valor de marca:** los *marketplaces*, mediante la implementación de nuevas tecnologías y puntos de contacto, permiten a los fabricantes gestionar de manera más eficiente las relaciones con sus clientes. La personalización de la experiencia de compra, basada en los gustos y comportamientos de los consumidores, ayuda a fortalecer la relación entre el fabricante y el cliente, incrementando la lealtad y el valor de la marca (Gallart Camahort, 2017).
- **Reducción de costes:** Bakos (1998) describe cómo la centralización de operaciones y el aprovechamiento de economías de escala dentro de los *marketplaces* han permitido a los fabricantes reducir significativamente los costos operativos. Por su parte, Kenney & Zysman (2016) y Tapia Arrate (2001) añaden a lo anterior una reducción de los costes de búsqueda de clientes y de las actividades de marketing para los fabricantes, lo que repercute en una mayor eficiencia en las cadenas de suministro con el despliegue de soluciones innovadoras como el *e-Procurement*¹ y la computación en la nube.
- **Diversificación del modelo de negocio:** en ocasiones, algunos *marketplaces* operan con múltiples configuraciones de negocio, lo que permite a los fabricantes aprovechar diferentes oportunidades de venta y minimizar riesgos operativos. (Hagiu & Wright, 2015). Es el caso de Amazon, que también integra otras iniciativas C2C como Amazon Renewed² o P2P como Amazon Handmade³ que permiten a los fabricantes ampliar su alcance y explorar nuevas fuentes de ingresos.

¹ El *e-Procurement* se refiere a la contratación y automatización online de las operaciones implicadas en el proceso de compra entre cliente y fabricante: pedido, recepción, facturación... (EDICOM, 2020).

² *Amazon Renewed* trata de darle una segunda vida a los productos, por lo que conecta a consumidores que quieren deshacerse de ciertos bienes, con otros interesados en ellos (Amazon, s.f.).

³ *Amazon Handmade* proporciona a los artesanos y fabricantes locales una plataforma para vender sus productos, promoviendo el comercio hecho a mano, conectando a individuos interesados en estos artículos (Amazon, s.f.).

- **Mejora de la confianza y transparencia en las transacciones:** el sistema de valoraciones y reseñas, así como los mecanismos de comparación de productos y la seguridad de las transacciones son elementos clave que sirven para reducir la asimetría de información y aumentar la confianza tanto de compradores como de fabricantes, mejorando la comunicación entre las partes y promoviendo el comportamiento de compra (Li et al., 2015; Santander Impulsa Empresa, s.f.). Igualmente, la retroalimentación de los usuarios de la plataforma tiene un impacto directo sobre la reputación de productos y fabricantes, generando confianza entre futuros compradores y mejorando la percepción del mercado.
- **Reducción de las barreras de entrada:** a pesar de la alta competencia en los *marketplaces*, estos disminuyen las barreras de entrada a las que se enfrentan los nuevos fabricantes ante otros más conocidos y establecidos en el mercado (Einav et al., 2016). De esta forma, los *marketplaces* permiten a los fabricantes emergentes incrementar la visibilidad de sus productos y competir en igualdad de condiciones frente a marcas más consolidadas, gracias a la audiencia global que ofrecen.

2.5. Ventajas e Inconvenientes de los *Marketplaces*

A pesar de que los *marketplaces* cuentan con innumerables ventajas tanto para compradores como para fabricantes, también conllevan una serie de desafíos. A continuación, se detallan las principales ventajas e inconvenientes asociados a este modelo de negocio.

Ventajas

- Mejor experiencia de cliente: la información compartida en la plataforma, el *feedback* de la comunidad *online*, la seguridad en las transacciones y la agilidad en el proceso de compra resultan en un aumento de la confianza y lealtad en el *marketplace*, y por tanto en los fabricantes que operan en él (Burtch et al., 2014). Asimismo, los consumidores se benefician de promociones exclusivas que surgen de la personalización de las estrategias de marketing (Hagiu & Wright, 2015).
- Aumento de la rentabilidad del *marketplace* a largo plazo: los sistemas de recomendación permiten un mejor perfilado del cliente, lo que lleva a personalizar la oferta de productos de los fabricantes de acuerdo con la demanda específica del consumidor. Esto se traduce en un mayor rendimiento de ventas y un aumento en la tasa de conversión, generando

beneficios a largo plazo para los fabricantes que operan en el *marketplace* (Zhou & Zou, 2023).

- Reducción de los costes operativos: las economías de escala permiten a los fabricantes recortar en costes variables, gracias a la optimización de la cadena de suministro y al poder de negociación del *marketplace* (Gallart Camahort, 2017). Este poder facilita la reducción de los costes asociados al transporte, almacenamiento y marketing, especialmente en productos de baja rotación o menor demanda, mejorando así la gestión financiera de los recursos de los fabricantes (Hagiu & Wright, 2015).
- Eficiencia logística: la mejora en las redes de distribución junto con la integración de procesos comerciales entre los fabricantes y el *marketplace* simplifican la cadena de valor desde el proveedor hasta el cliente final (Bakos, 1998; Tapia Arrate, 2001). Esto permite a los fabricantes mejorar su eficiencia, reducir los tiempos de entrega y minimizar los costes de inventario.
- Aumento positivo de la competitividad: la implementación de herramientas avanzadas de Inteligencia Artificial (IA) y la personalización de la experiencia de compra permiten a los fabricantes destacar en el *marketplace*. La integración de estas tecnologías contribuye a crear valor de marca y ofrece una ventaja competitiva, al mejorar tanto la visibilidad como la relevancia de los productos entre los consumidores (Gallart Camahort, 2017).

La **Figura 3** muestra las ventajas más importantes que los *marketplaces* ofrecen a los fabricantes:

Figura 3: Beneficios del marketplace para el fabricante.



Fuente: Javed (2022)

Inconvenientes

- Reducción del margen de beneficios: la saturación del mercado en el *marketplace* empuja a los fabricantes a recortar precios para mantenerse competitivos (Li et al., 2015). Zhou & Zou (2023) afirman que este ajuste podría llegar a perjudicar no sólo a los propios fabricantes, sino también a la plataforma, sobre todo erosionando los márgenes de beneficio de aquellos con menor antigüedad en el *marketplace*. La lucha por obtener cierta ventaja competitiva intensifica los desafíos que experimentan las empresas por intentar diferenciar sus productos con atributos personalizados (Bakos, 1998). Además, en ocasiones, la segmentación excesiva de los clientes en base a las recomendaciones y los hábitos de compra podría afectar la captación de nuevos consumidores que no entran dentro del perfil típico, repercutiendo negativamente en las ventas (Zhou & Zou, 2023).
- Fragmentación de la imagen de marca: la diversificación de canales a través del *marketplace* dificulta la gestión consistente de las actividades de marketing llevadas a cabo en cada uno de ellos, por lo que podría llegar a distorsionar la imagen de marca que percibe el cliente (Hagiu & Wright, 2015). Al depender de la plataforma para vender sus productos, los fabricantes podrían perder el control sobre la experiencia del cliente y su propia reputación, lo que podría canibalizar las ventas en sus propios canales. Maier & Wieringa (2021) sostienen que la intermediación del *marketplace* podría interceder desfavorablemente en la relación fabricante-cliente.
- Desafíos tecnológicos: la implementación de las nuevas tecnologías puede suponer barreras de entrada para los fabricantes más pequeños o aquellos con menores recursos, ya que su adopción puede ser costosa y su complejidad alta (Gallart Camahort, 2017; Tapia Arrate, 2001). Por tanto, estas barreras podrían limitar la capacidad de ciertos fabricantes para competir de manera efectiva.
- Riesgos regulatorios: los *marketplaces* que operan internacionalmente están sujetos a las normativas de cada país o cada producto en particular. Tanto su incumplimiento, como su desconocimiento derivado de la evolución en la legislación, podrían afectar severamente la operación de estos mercados, y tener graves consecuencias sobre los fabricantes (Einav et al., 2016).
- Dependencia de la plataforma: los fabricantes dependen en gran parte de las normas que impone el *marketplace* y de las decisiones que tome desde su posición de poder (Santander Impulsa Empresa, s.f.). Kenney & Zysman (2016) exponen el hecho de que imponer comisiones elevadas o ajustar la visibilidad de ciertos productos conlleva abusos

de poder por parte de las plataformas que se convierten en monopolistas virtuales. Por su parte, las ventas de los fabricantes se ven comprometidas por su reputación y valoraciones en el entorno *online*, lo que puede verse gravemente afectado por sistemas de retroalimentación imperfectos que corren el riesgo de ser manipulados (Einav et al., 2016).

2.6. Historia y Evolución de los *Marketplaces*

Desde su aparición en la década de 1990, los *marketplaces* no sólo han transformado la manera en que los consumidores interactúan con los fabricantes, sino que también han provocado un cambio radical en la estructura convencional de distribución y venta. El auge de Internet y de la *World Wide Web* empujó a los minoristas más tradicionales a sumergirse en el entorno virtual, lo que progresivamente supuso una adición de canales de distribución alternativos, brindando al consumidor la opción de realizar compras desde la comodidad de su hogar (Gallart Camahort, 2017).

Así pues, con la globalización y el desarrollo de las nuevas tecnologías, como el lenguaje de marcado extensible (XML) y el intercambio electrónico de datos (EDI), surgieron los primeros *marketplaces*, dando a luz a Amazon en 1994, establecido en sus inicios como una gran librería *online*, que más tarde extendería su oferta a todo tipo de bienes y servicios, consolidándose como un gigante del *e-commerce* (Tapia Arrate, 2001). La aparición de Amazon, y el incremento de la demanda en el entorno virtual aceleró la creación de nuevos *marketplaces* como Alibaba (1999) o Zalando (2008), que siguieron el mismo modelo de negocio que éste (Gallart Camahort, 2017).

Sin embargo, las novedades de los *marketplaces* estuvieron primeramente marcadas por la introducción del **sistema de señalización** por el cual los compradores tenían facultad de valorar los productos ofrecidos por los fabricantes en la plataforma, fomentando la confianza entre usuarios debido a la credibilidad de la información recogida y facilitando al consumidor la toma de decisiones (Li et al., 2015). La cálida acogida del primer sistema de valoraciones implementado por eBay en 1996 provocó la imitación de sus competidores que no tardaron en apreciarlo.

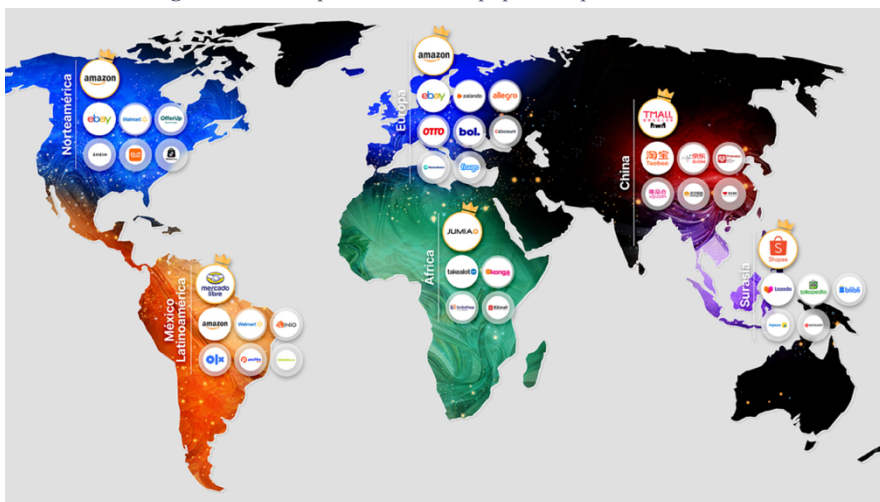
A medida que el mercado fue evolucionando, los sistemas de intercambio electrónico de datos (EDI) fueron sustituidos por alternativas mucho más innovadoras y flexibles como el *e-Procurement* (Tapia Arrate, 2001). Igualmente, los avances tecnológicos permitieron optimizar la cadena de suministro y mejorar la comunicación entre partes, reduciendo los costes operativos y mejorando la eficiencia del proceso de compra (Bakos, 1998; Gallart Camahort, 2017). Así fue

como Amazon introdujo su servicio *Fulfillment by Amazon* (FBA) ⁴ en donde ofrecía soluciones logísticas avanzadas a los fabricantes que operaban en su plataforma, ejemplo que después seguirían sus competidores (Corrot & Nussenbaum, 2023).

Por otro lado, aunque los **sistemas de recomendación** llegaron a principios del siglo XXI, las revoluciones tecnológicas que se sucedieron, entre las que cabe destacar el *Big Data*, la Inteligencia Artificial y, especialmente el *Machine Learning*, han permitido refinarlos hasta límites insospechables. Esto ha llevado a una era de competencia basada en recomendaciones personalizadas, donde los fabricantes pueden ofrecer productos más alineados con las necesidades y preferencias de los consumidores (Corrot & Nussenbaum, 2023).

Hoy en día, los *marketplaces* B2C continúan expandiéndose y adaptándose a las nuevas demandas del mercado. En la actualidad, los **desafíos** más típicos son la dependencia tecnológica, y la necesidad de cumplir con regulaciones internacionales cambiantes. Por su parte, los fabricantes también enfrentan el reto de mantener su competitividad en un entorno donde los grandes *marketplaces* dominan el mercado, lo que puede poner en riesgo a las pequeñas marcas que intentan destacar en un panorama global. Maier & Wieringa (2021) proponen que una de las posibles soluciones pasaría por asegurar la complementariedad de los canales en los que opera el fabricante, ofreciendo una serie de productos en el *marketplace*, y otros distintos en su propia página web.

Figura 4: Marketplaces B2C más populares por continentes.



Fuente: Parra (2024)

⁴ El *Fulfillment by Amazon* (FBA) es el programa de almacenamiento, envío y servicio de atención al cliente que ofrece Amazon a los fabricantes (Amazon, s.f.).

Por último, el peso que se le ha dado a los modelos de gobernanza en los últimos años tampoco deja indiferente a este sector, que aspira a encontrar el **equilibrio entre innovación y competitividad** (Tiwana, 2014). Esta mentalidad de mejora continua ha llevado a los *marketplaces* a consolidarse como el modelo dominante en el entorno virtual, tal y como se puede comprobar en la *Figura 4*, y en donde, además, se puede observar cómo Amazon lidera el mercado europeo.

Si bien, los *marketplaces* B2C continúan expandiéndose y ofreciendo a los fabricantes oportunidades para mejorar su distribución, visibilidad y eficiencia. La capacidad de adaptación y los recursos tecnológicos disponibles aseguran que estos modelos seguirán siendo una parte integral del comercio electrónico en el futuro (Corrot & Nussenbaum, 2023). Así pues, el crecimiento de los *marketplaces* está lejos de sufrir una desaceleración, más aún en un entorno tan dinámico como el actual, lo que asegura su supervivencia en el largo plazo.

CAPÍTULO III: Los Sistemas de Recomendación

El tercer capítulo se centra en los fundamentos del *Machine Learning* y su aplicación en los sistemas de recomendación, fundamentales para la personalización en el comercio electrónico. Primero, se explicará el funcionamiento del *Machine Learning* y su impacto en el marketing digital, donde ha transformado las estrategias de personalización y mejora de la experiencia del consumidor.

Luego, se profundizará en los sistemas de recomendación, detallando su concepto, características, funcionamiento y los diferentes tipos de filtrado utilizados. Finalmente, se analizará el impacto de estas tecnologías en el comportamiento del consumidor, evaluando cómo influyen en la toma de decisiones y optimizan la experiencia de compra.

3.1. El *Machine Learning* y los Sistemas de Recomendación

Desde sugerencias de compra que parecen leídas directamente de nuestra mente hasta plataformas que entienden nuestros gustos musicales, actividades que antes parecían sacadas de novelas de ficción son ahora parte de nuestra realidad cotidiana gracias al *Machine Learning*. Este avance tecnológico es responsable de sugerirnos ese artículo que hemos estado mirando, de optimizar la clasificación de productos según nuestras preferencias en Amazon, o de recomendar canciones que se alinean con nuestros intereses en Spotify (BBVA, s.f.).

El *Machine Learning* (ML), o Aprendizaje Automático en español, es una rama de la Inteligencia Artificial (IA) que se encarga de analizar un gran volumen de datos a alta velocidad, identificando patrones y elaborando predicciones a través de una serie de algoritmos y modelos estadísticos que, aplicando métodos iterativos basados en históricos y experiencias pasadas, aprenden con el tiempo sin ser específicamente programados para ello, de tal forma que permiten automatizar tareas minimizando la intervención humana (Ngai & Wu, 2022; Alpaydın, 2021).

Tal y como se ha mencionado con anterioridad, los modelos de *Machine Learning* cuentan con una serie de características únicas, entre las que merece la pena resaltar son:

- **Capacidad de aprendizaje automático en el tiempo:** su capacidad de aprendizaje no requiere ser programada explícitamente. (Ngai & Wu, 2022).

- **Adaptabilidad a nuevos conjuntos de datos:** siendo su precisión mayor, cuanto mayor sea el volumen de información procesado (Mahesh, 2019).
- **Mejora continua:** los algoritmos se optimizan continuamente a través de métodos iterativos, consiguiendo mejor rendimiento a medida que pasa el tiempo (APD, 2024).
- **Capacidad predictiva:** permite realizar predicciones a partir de datos históricos, anticipando las tendencias del mercado y estimando la demanda (Siegel, 2016).
- **Automatización de tareas complejas:** minimiza la intervención humana en tareas difíciles, como la toma de decisiones, o la gestión logística (IBM, s.f.; Salesforce, s.f.).
- **Flexibilidad y polivalencia:** se aplica a una gran variedad de sectores e industrias, ya que facilita la resolución de tareas complejas (Goodfellow et al., 2016).

Asimismo, los algoritmos de *Machine Learning* pueden aprender de los datos de cuatro formas:

- a) Aprendizaje supervisado o *supervised learning*:** el algoritmo se entrena con un conjunto de datos (*training set*) formado por pares de entrada y salida, con el fin de hacer predicciones sobre nuevos datos (*test set*) (Salesforce, s.f.). Se usa en regresión, clasificación, y aplicaciones como recomendaciones de Netflix o clasificación de correos como *spam*. (BBVA, s.f.; SAP, s.f.).
- b) Aprendizaje no supervisado o *unsupervised learning*:** el algoritmo no cuenta con un aprendizaje previo, sino que busca patrones en datos no etiquetados, agrupándolos de manera significativa. Se aplica en forma de *clustering* para la segmentación de clientes y la detección de anomalías en ciberseguridad (Iberdrola, s.f.).
- c) Aprendizaje semisupervisado o *semi-unsupervised learning*:** combina los dos aprendizajes anteriores, por lo que el algoritmo es capaz de usar datos estructurados para etiquetar datos no estructurados en un proceso conocido como “pseudoetiquetado” (Amazon Web Services, s.f.). Se aplica en el etiquetado de imágenes y en el análisis del lenguaje.
- d) Aprendizaje por refuerzo o *reinforcement learning*:** los algoritmos aprenden por ensayo y error, con un sistema de recompensas y penalizaciones según las acciones tomadas. Cuanto más se acerca a un objetivo, mayores son las recompensas, lo que permite al modelo identificar las decisiones más favorables. Se utiliza en herramientas de reconocimiento facial y en la gestión de carteras de inversión (Iberdrola, s.f.; BBVA, s.f.).

En el contexto del Marketing, el aprendizaje supervisado se emplea a la hora de realizar predicciones basadas en hábitos de compra o el historial de navegación, el aprendizaje no

supervisado para segmentación de clientes e identificación de patrones de consumo emergentes (Herhausen et al., 2024), y el semisupervisado en aquellos casos en los que se dispone de información parcial sobre el cliente y sus preferencias (Ma & Sun, 2020).

3.2. El *Machine Learning* en Marketing

La llegada de la Inteligencia Artificial, y con ella la del *Machine Learning*, ha revolucionado radicalmente el comercio electrónico, con herramientas que permiten mejorar la experiencia del usuario y optimizar la toma de decisiones empresariales. El auge en la adopción de tecnologías de Aprendizaje Automático en el comercio electrónico responde a la necesidad de personalizar las interacciones con el cliente, automatizar procesos y mejorar el rendimiento económico que perciben estas plataformas, siendo capaces de predecir el comportamiento de los consumidores y ajustar los precios en tiempo real.

Así pues, el *Machine Learning* apuesta por un marketing más inteligente y eficiente, centrado no sólo en entender las necesidades del consumidor, sino también en comprender mejor su comportamiento, con el fin de desarrollar estrategias que se ajusten perfectamente a sus exigencias. Tanto es así que, el cambio de paradigma ha supuesto una nueva etapa en esta disciplina, la cual ya ha recibido el nombre de “*Transformative Marketing*”. Kumar (2018) define el “Marketing Transformador” como un Marketing que se apoya en la tecnología y se adapta a las cambiantes tendencias del mercado, mejorando la eficiencia operativa y creando un valor adicional para sus clientes.

La evolución de los algoritmos de Aprendizaje Automático ha impulsado la investigación en **Marketing comportamental**, facilitando el procesamiento de grandes cantidades de datos y el reconocimiento de patrones ocultos en las conductas de los consumidores (Hagen et al., 2020; Ma & Sun, 2020). Bradlow et al. (2017) sostienen que este análisis predictivo viene de la mano del **Big Data** y de su capacidad para proporcionar información sobre cinco dimensiones de datos:

- **Datos sobre el cliente:** historial y frecuencia de compra, preferencias, o navegación en el sitio web. Permiten obtener perfiles de cliente más precisos y personalizar la oferta.
- **Datos sobre el producto:** atributos, disponibilidad en el inventario, popularidad, tasa de devolución... Permiten una mejor gestión de inventarios y facilitan la toma de decisiones relativas a promociones y descuentos.

- Datos sobre la ubicación geográfica: gustos locales, disponibilidad en distintas regiones... Estos datos ayudan a gestionar la logística de la cadena de suministro.
- Datos sobre el tiempo: fecha y hora de la compra, tendencias estacionales... Son muy relevantes en estrategias de discriminación de precios dependiendo de la demanda.
- Datos sobre los canales: en línea, físicos o una combinación de ambos. Definen el diseño de la estrategia de omnicanalidad que rige las interacciones con el cliente.

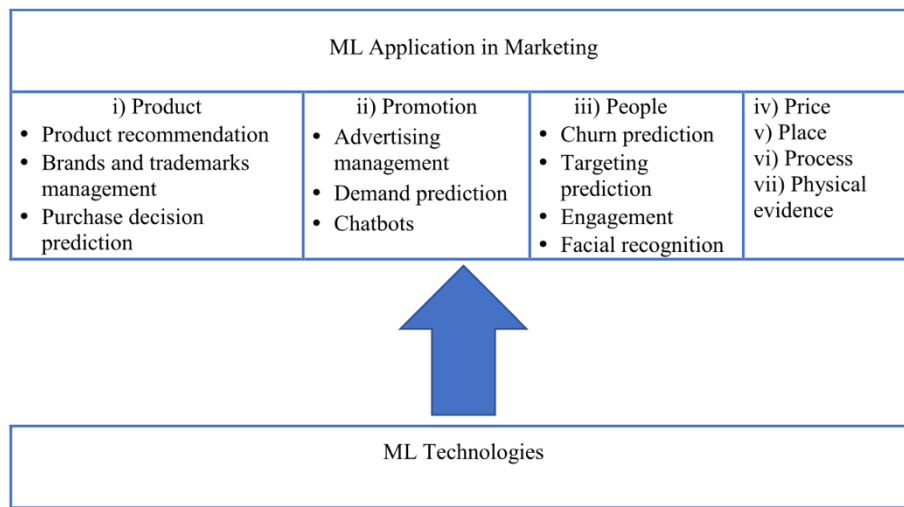
De esta forma, la suma de fuerzas entre *Machine Learning* y *Big Data* desemboca en la optimización de las estrategias de marketing en tiempo real y el aumento de la eficiencia operativa del fabricante, mejorando sus márgenes de beneficio a la vez que mejora la satisfacción del cliente con una experiencia personalizada (Grewal et al., 2017).

A pesar de todo, aquellas empresas que saben aprovecharse de ambas herramientas distribuyen de manera óptima sus recursos, están mejor posicionados para cubrir las demandas del mercado, y se mantienen a la cabeza de la competencia. Y es que según Ngai & Wu (2022) las **estrategias basadas en datos** constituyen la principal fuente de *insights* sobre los consumidores en el campo del *Marketing Research*, y ayudan a reducir los costes operativos del minorista a largo plazo y aumentar su rentabilidad.

Así pues, el *Machine Learning* afecta a cada una de las variables de decisión del Marketing, que autores como Huang & Rust (2021) y Ngai & Wu (2022) resumen así:

- Producto: el ML se aplica a la personalización de productos y servicios, agilizando las decisiones de compra y mejorando la experiencia del cliente.
- Precio: los ML permite ajustar los precios de forma dinámica en función de la demanda y el comportamiento del consumidor con tal de maximizar los ingresos.
- Punto de venta: el ML ayuda a identificar los mejores canales de venta, mejorando la logística y la gestión de inventarios, automatizando y anticipando ciertos pedidos.
- Promoción: los algoritmos de *Machine Learning* optimizan el diseño de las campañas de marketing, incrementando su efectividad al particularizar el mensaje que se desea transmitir según el comportamiento del usuario.

Figura 5: Aplicación de los algoritmos de Machine Learning cada una de las variables de decisión de marketing.



Fuente: Ngai & Wu (2022)

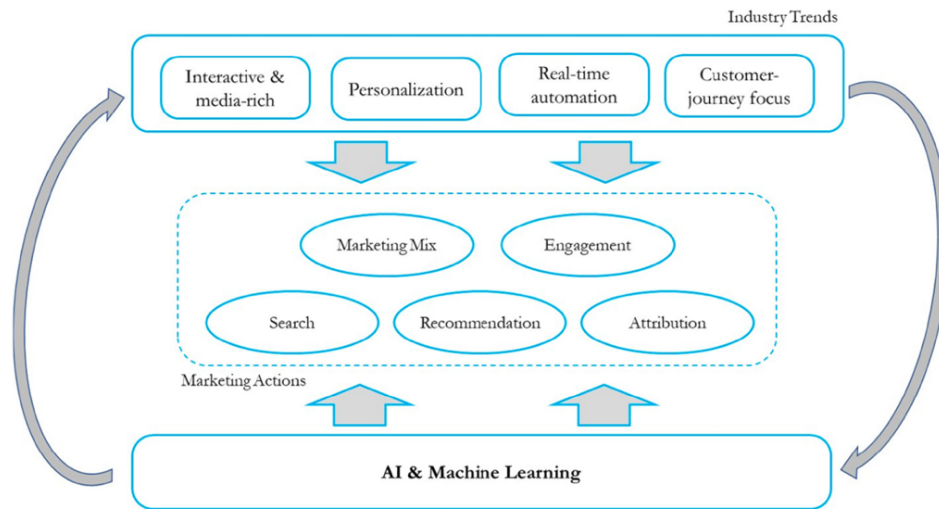
La **Figura 5** muestra cómo el *Machine Learning* afecta a cada una de las variables de decisión del Marketing. Si bien, existen otras variables como “Personas”, que ayuda a segmentar el mercado gracias a la aplicación de tratamientos heterogéneos, esto es, implementar distintos tipos de interacciones y contemplar cómo afectan individualmente a los usuarios (Hagen et al., 2020).

De manera análoga, Huang & Rust (2021) argumentan que la **Teoría STP** que se ocupa de la Segmentación, *Targeting* y Posicionamiento, se emplea en Marketing digital junto al *Machine Learning* para clasificar en grupos al conjunto de clientes en función de los patrones observados, identificar cuáles son los mejores segmentos a los que debe ir dirigido un producto o servicio y posicionarlos de la manera más efectiva posible en la mente de los consumidores.

Pero a medida que evoluciona la tecnología, también lo hace el enfoque con la aparición de **modelos de negocio innovadores** como el bautizado “*shipping-then-shopping*”, en el que la empresa envía directamente a los consumidores productos recomendados por los algoritmos de *Machine Learning*. Los clientes pueden probarlos y decidir si desean quedárselos y comprarlos, o devolverlos sin compromiso. Empresas como Stitch Fix ya lo están implementando con éxito (Davenport et al., 2020).

No obstante, Huang & Rust (2018) proponen otro modelo de negocio que combina empleados humanos y algoritmos de *Machine Learning*, donde los humanos gestionan las interacciones empáticas con los clientes, mientras que la IA automatiza tareas simples como responder FAQs a través de chatbots. La IA actúa como una extensión de las capacidades humanas, sin reemplazarlas (Davenport et al., 2020).

Figura 6: Tendencias en el nuevo ecosistema de Marketing impulsadas por la IA y el ML.



Fuente: Ma & Sun (2020)

Ma & Sun (2020) subrayan que otras tendencias pasan por poner el foco en el **customer journey**, esencial para entender la lógica detrás de su comportamiento, tal y como muestra la **Figura 6**. Por último, otra de las tendencias más populares consiste en desarrollar soluciones de **realidad aumentada** con el objetivo de que los consumidores sean capaces de interactuar con el producto de manera virtual (Grewal et al., 2017).

A pesar de los avances en Machine Learning, aún hay áreas que requieren más investigación, como la interpretabilidad de los modelos, que necesita un análisis más profundo para entender no solo los resultados, sino también cómo y por qué ocurren (Huang & Rust, 2018; Hagen et al., 2020). Los *marketplaces* B2C deben comprender cómo se generan las predicciones para garantizar transparencia y confianza en los clientes. Davenport et al. (2017) también puntualizan que es necesario desarrollar algoritmos con mayor conciencia contextual para mejorar la efectividad de las recomendaciones.

En conclusión, el "Marketing Transformativo" que integra el Machine Learning permite anticiparse a las necesidades de los consumidores, mejorar la eficiencia del marketing y ofrecer un valor añadido a largo plazo. Este nuevo paradigma de Marketing está liderando la transición hacia una era marcada por los avances tecnológicos (Kumar, 2018).

3.3. Sistemas de Recomendación: Concepto y Características

Los sistemas de recomendación han revolucionado el comercio electrónico desde su aparición en la década de 1990. El desarrollo de la World Wide Web y el auge de los negocios en línea puso de manifiesto la necesidad de aprender de los consumidores para así ofrecerles una experiencia de compra única, impulsando la investigación en este área (Domingos, 2012; Schafer et al., 2001).

Hoy en día, la información disponible en la web es cada vez más amplia, y no son pocos los usuarios que recurren a motores de búsqueda como Google o Yahoo! para encontrar todo cuanto desean en ella (Mahesh, 2019). Del mismo modo, cientos de consumidores acuden a plataformas como Amazon con el fin de encontrar ese artículo que echan en falta, no sin antes procesar cuidadosamente varias docenas de ellos hasta dar con el más conveniente (Zhang et al., 2019). La creciente variedad y accesibilidad de la información ha redefinido la forma en que vivimos e interactuamos con nuestro entorno, pero también ha traído consigo cierta sobrecarga cognitiva por “infoxicación” (Ngai & Wu, 2022; Khusro et al., 2016).

Ngai & Wu (2016) y Trabelsi et al. (2021) destacan que una de las soluciones para lidiar con esta “infoxicación” en el comercio online pasa por implementar sistemas de recomendación, agilizando el proceso de compra y facilitando la toma de decisiones del cliente. Los **sistemas de recomendación** son herramientas de software que recogen y extraen información sobre las preferencias y el comportamiento de los usuarios, proporcionándoles sugerencias de artículos o productos que les pueden resultar de interés (Schafer et al., 2001). Estos sistemas son especialmente útiles cuando el cliente en cuestión carece de la experiencia necesaria para evaluar la abrumadora cantidad de productos que el marketplace pone a su disposición. Y es que cuanto mayor es la variedad, mayor es el riesgo de elegir un artículo que no se ajusta del todo a sus necesidades.

Así pues, los sistemas de recomendación se nutren de distintos tipos de datos para realizar sus sugerencias, entre los que destacan: la demografía del usuario, su historial de compras, sus comentarios y valoraciones... Esta información puede ser recabada de manera **explícita**, por ejemplo, pidiéndole al consumidor que escriba una reseña, preguntándole por su edad, o bien de manera **implícita**, estudiando su comportamiento al navegar por el sitio web (Herhausen et al., 2024; Ricci et al., 2015). En este sentido, los sistemas de recomendación más básicos emplean únicamente reseñas a la hora de elaborar sugerencias, mientras que los sistemas más completos

dependen de estructuras de datos mucho más complejas, como las descripciones de los productos o las relaciones sociales entre clientes.

Zhang et al. (2023) y Ngai & Wu (2022) sostienen que los sistemas de recomendación recogen y almacenan principalmente tres **tipos de datos**:

- 1) Productos: son los elementos objeto de recomendación y vienen caracterizados por su descripción, atributos o utilidad que proporcionan a un determinado consumidor. Un producto es interesante para un usuario cuando le resulta de valor añadido.
- 2) Usuarios: son los individuos que interactúan con el sistema de recomendación con diversos fines y suelen identificarse en primera instancia de forma sociodemográfica (género, edad, profesión...). A partir de dichas interacciones, los modelos de recomendación elaboran el perfil de cliente, concretando sus preferencias y necesidades.
- 3) Transacciones: se refiere a la información que almacena el sistema a medida que el usuario interactúa con él y toma diferentes formas: reseñas, clics, historial... Estos datos son cruciales a la hora de entrenar el algoritmo de recomendación.

El **origen** de los sistemas de recomendación se remonta a 1992, cuando investigadores del MIT Media Lab dieron vida al famoso “Tapestry”, uno de los primeros sistemas en aplicar las técnicas de filtrado colaborativo y que permitía a los usuarios elaborar recomendaciones manuales a otros con gustos parecidos. Con el desarrollo de las nuevas tecnologías, este enfoque manual se vio rápidamente reemplazado en 1994 por “GroupLens”, un sistema automatizado de filtrado colaborativo que implementaba algoritmos de Aprendizaje Automático para realizar recomendaciones basadas en la similitud entre usuarios. Sin embargo, no fue hasta la llegada de Amazon en 1994 que se empezaron a adoptar los sistemas de recomendación a gran escala en el entorno virtual (Raghuwanshi & Pateriya, 2019; Khusro et al., 2016).

Por su parte, los 2000 estuvieron marcados por el avance del comercio digital y el perfeccionamiento de los algoritmos de **Machine Learning**, dando lugar al desarrollo de nuevos enfoques de recomendación como el filtrado basado en contenido. El “Premio Netflix” (2009) otorgado a “BellKor” fue otro de los hitos que impulsaron el progreso de esta tecnología al lograr batir la precisión de las predicciones realizadas por el algoritmo propio de Netflix, conocido como “Cinematch”, en un 10%. El ánimo del concurso, convocado en 2006, no era otro que el de descubrir el mejor algoritmo de filtrado colaborativo capaz de predecir las valoraciones de los usuarios de la plataforma de entretenimiento (Thorat et al., 2015).

Ricci et al. (2015) señalan que la evolución de los sistemas de recomendación durante las últimas dos décadas ha sido tan notable que la **comunidad académica** cada vez le otorga más peso en sus investigaciones. La inclusión de artículos de esta índole en revistas académicas como el “*International Journal of Electronic Commerce*” y conferencias como “RecSys” (establecidos en 2006 y 2007, respectivamente), son sólo prueba del creciente interés en estas herramientas.

El rápido procesamiento de los datos almacenados y la capacidad para diseñar experiencias personalizadas, son algunos de los motivos que justifican la implantación de estos sistemas por parte de los *marketplaces*, pero no son los únicos. Herhausen et al. (2024) y Zhang et al. (2023) enumeran otras **razones que respaldan su instauración**:

- Incrementar la venta de artículos: se trata de convertir visitantes en compradores, sugiriendo productos que el cliente no sabía que necesitaba, lo que aumenta la tasa de conversión y la efectividad de las actividades de marketing.
- Mejorar la venta cruzada de productos o *cross-sell*: consiste en ofrecer al consumidor productos complementarios a los que tiene pensado comprar, incrementando el volumen de compra y con ello los ingresos del fabricante.
- Aumentar la satisfacción del cliente: un sistema de recomendación diseñado adecuadamente provee sugerencias relevantes, reduce la fatiga cognitiva y fomenta la confianza en la plataforma. Una interfaz fácil de usar con sugerencias precisas promueve la interacción con el cliente y aumenta la probabilidad de que éste se fíe de ellas.
- Mejorar la eficiencia operativa: los sistemas de recomendación almacenan y predicen datos sobre los gustos del consumidor, pudiendo anticipar la demanda. A su vez, esto facilita la gestión de inventarios y promociones, lo que aumenta la capacidad de respuesta de las empresas.
- Incrementar la fidelización del cliente: cuanto más usa el cliente el sistema, más precisas son las recomendaciones, lo que fortalece la relación con la empresa y promueve compras recurrentes. Esta estrategia otorga una de las mayores ventajas competitivas *online*.

No obstante, de acuerdo con Ricci et al. (2015), los sistemas de recomendación se pueden aplicar con distintos **propósitos**, entre los que destacan: ofrecer al usuario sugerencias relevantes, proporcionarle una secuencia o un conjunto de productos, facilitarle a navegar por la plataforma, o permitirle expresarse, ayudar e influenciar a otros clientes a través del sistema de valoraciones.

Al mismo tiempo, no sólo es esencial diseñar correctamente el sistema de recomendación, sino también evaluar su desempeño. Ricci et al. (2015) señalan que esta **evaluación** se realiza en dos etapas: una primera en la fase de diseño y otra en la fase de implementación. En la fase de diseño, la evaluación se ejecuta *off-line*, comparando las recomendaciones que realizaría el algoritmo frente al histórico de datos almacenados. No obstante, esta primera evaluación sólo sirve para hacerse una idea de la calidad de las predicciones.

Por el contrario, la segunda evaluación que tiene lugar durante la fase de implementación consiste en obtener *insights* sobre la satisfacción del cliente y su experiencia con el sistema. A diferencia de la etapa anterior, esta evaluación se desarrolla *online* y puede estar dirigida a un único usuario, o a un *focus group* en forma de experimento controlado, donde los usuarios interactúan con distintas versiones del sistema.

Si bien, Schafer et al. (2001) aclaran que las recomendaciones pueden ser personalizadas y no personalizadas, según se adapten a los intereses particulares de cada usuario y en función del carácter de los datos utilizados.

- Recomendaciones personalizadas: giran en torno a las preferencias individuales del consumidor. Se fundamentan en datos como el historial de compras o de navegación, las reseñas anteriormente publicadas, y la interacción del usuario con la plataforma.
- Recomendaciones no personalizadas: vienen determinadas por métricas generales como las valoraciones promedio, o los artículos más populares dentro de la plataforma, sin adaptarlas específicamente a cada usuario.

Adicionalmente, Schafer et al. (1999) explican que existe toda una taxonomía a la hora de clasificar las técnicas empleadas para efectuar las recomendaciones, y que las divide en dos grupos:

a) Recomendaciones Manuales vs. Automáticas:

- Manuales: son aquellas que se crean de forma manual por el propio fabricante para promocionar ciertos bienes o servicios. En ellas, el nivel de personalización es bajo.
- Automáticas: son aquellas generadas por algoritmos, sin intervención humana. Se elaboran según éste vaya interactuando con la plataforma digital mediante el estudio de su comportamiento y de datos históricos, por lo que son altamente personalizadas.

b) Recomendaciones Persistentes vs. Efímeras:

- Persistentes: se mantienen relevantes durante un período de tiempo prolongado. Se centran en intereses del usuario a largo plazo y se basan en el análisis del historial de navegación completo. Son recomendaciones estables y predecibles.
- Efímeras: se recopilan en una sola sesión de navegación y tienen un carácter temporal. Se fundamentan en intereses específicos del usuario en un cierto momento. Son recomendaciones oportunas que pueden llegar a influir en el comportamiento del consumidor.

Hecha esta clasificación y vistos los tipos de recomendaciones, es preciso aclarar que el presente trabajo se dedicará al estudio exclusivo de aquellas recomendaciones personalizadas de tipo automático implementadas a partir de algoritmos de *Machine Learning*.

3.4. Funcionamiento y Tipos de Sistemas de Recomendación

Como ya se ha visto, los algoritmos de *Machine Learning* conforman la base sobre la cual se construyen los sistemas de recomendación personalizados. Si bien, aunque hay distintos tipos de aprendizaje y sus algoritmos son variados, de acuerdo con IBM (s.f.), su funcionamiento base es común y consta de tres etapas:

- 1) **Función de decisión:** el algoritmo define un modelo matemático o estadístico a partir de una serie de datos de entrada en los cuales detecta un patrón y devuelve la salida esperada.
- 2) **Función de error:** evalúa la precisión del modelo construido, fijándose en la diferencia entre las predicciones y los valores reales conocidos, que no es más que el error.
- 3) **Actualización y optimización:** es el proceso iterativo en que el modelo trata de reducir el error, ajustando la toma de decisiones hasta alcanzar el umbral de precisión.

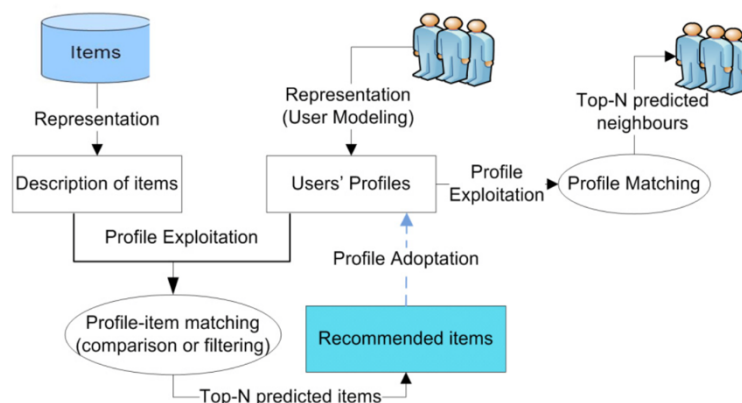
Khusro et al. (2016) y Ricci et al. (2015) defienden funcionamiento aplicado a los sistemas de recomendación es simple y parte de dos sets de datos, J y U que, combinados dan lugar al set R de las recomendaciones:

$$\left. \begin{array}{l} J \equiv \{j_1, j_2, j_3, \dots, j_n\} \rightarrow \text{Set de productos} \\ U \equiv \{u_1, u_2, u_3, \dots, u_m\} \rightarrow \text{Set de usuarios} \end{array} \right\} f: U \times J \rightarrow R$$

Y es que para todo usuario $u \in U$, el sistema encuentra una recomendación r_{uj} que maximiza la utilidad f que obtiene éste al comprar dicho producto. La utilidad habitualmente se refiere a la predicción que hace el algoritmo de *Machine Learning* de la valoración o *rating* que daría dicho usuario al artículo en cuestión, como reflejo del interés o relevancia esperada. Para su computación se emplean los datos almacenados sobre el usuario y se divide a los *ratings* en un set de entrenamiento (*training set*), responsable del aprendizaje del algoritmo, y un set de prueba (*test set*), utilizado para evaluar las predicciones. La precisión del modelo se calcula tomando métricas estadísticas populares como la raíz del error cuadrático medio (RMSE) o el error absoluto medio (MAE).

La **Figura 7** representa el funcionamiento generalizado de un modelo de recomendación.

Figura 7: Funcionamiento general de un sistema de recomendación.



Fuente: Khusro et al. (2016)

Por tanto, los *marketplaces* deberán primero reflexionar sobre los propósitos que persiguen con la implantación de estos sistemas, para así poder ajustar el grado de automatización y persistencia de las recomendaciones personalizadas, y elegir la técnica de filtrado que mejor se adapte a las necesidades y el perfil de sus clientes (Van Heusden, 2023). Estas técnicas de filtrado son tres: filtrado colaborativo, filtrado por contenido y filtrado híbrido.

3.4.1. Filtrado Colaborativo

Los sistemas de recomendación de filtrado colaborativo (*Collaborative Filtering*, CF) se caracterizan por recopilar y almacenar información referida a patrones de comportamiento, valoraciones o preferencias de los usuarios activos en la plataforma (Thorat et al., 2015). Su objetivo es predecir la relevancia de ciertos productos para un usuario específico, comparando sus intereses particulares con los del resto de la comunidad. De este modo, se le presentan

recomendaciones basadas en usuarios con perfiles y gustos similares, que previamente han valorado de forma positiva dichos productos (Raghuwanshi & Pateriya, 2019; Schafer et al., 1999).

Por su parte, los sistemas de filtrado colaborativo se implementan en dos enfoques según la naturaleza de sus algoritmos:

1) **Filtrado colaborativo con enfoque basado en memoria o instancias (*memory-based approach*):** en este enfoque, el algoritmo almacena todos los datos disponibles sobre productos, usuarios, valoraciones e interacciones y los utiliza para calcular directamente las similitudes y elaborar las recomendaciones. El algoritmo más típico es el de los **Vecinos más Próximos** (*k-Nearest Neighbors* o k-NN), que sirve para clasificar nuevos datos observando su semejanza con los ya disponibles, definiendo un set de vecinos $N(u)$ similares al usuario. A su vez, este enfoque tiene dos vertientes:

- a) Filtrado colaborativo basado en usuarios (*user-based*): las recomendaciones se realizan tomando como referencia a usuarios con gustos parecidos al sujeto. La valoración del artículo estimada para un usuario es el resultado de calcular la media ponderada de las valoraciones que los k vecinos más cercanos al usuario en cuestión han otorgado a dicho artículo (Thorat et al., 2015; Raghuwanshi & Pateriya, 2019).

Figura 8: Funcionamiento de un sistema de recomendación por filtrado colaborativo basado en usuarios.



Fuente: Elaboración propia (2024)

- b) Filtrado colaborativo basado en artículos (*item-based*): las recomendaciones se realizan tomando artículos similares a aquellos que el usuario ha evaluado positivamente con anterioridad. La predicción de la relevancia para un artículo se calcula considerando un conjunto de artículos similares a éste y calculado la media ponderada de las reseñas ya escritas por el usuario (Raghuwanshi & Pateriya, 2019).

Figura 9: Funcionamiento de un sistema de recomendación por filtrado colaborativo basado en artículos.



Fuente: Elaboración propia (2024)

2) **Filtrado colaborativo con enfoque basado en modelos (*model-based approach*):** a diferencia del caso anterior, este enfoque requiere construir modelos predictivos a partir de los datos disponibles sobre la interacción entre usuarios y artículos. El fundamento de estos modelos reside en su capacidad para agrupar a usuarios o artículos en categorías o factores latentes (He et al., 2017). Los factores latentes se definen como aquellas características o patrones aparentemente ocultos que están detrás de las correlaciones entre usuarios y productos y que explican las valoraciones observadas. Así pues, cuanto mayor es la correlación entre un producto y un consumidor, mayor es la probabilidad de que éste figure como una de las recomendaciones (Thorat et al., 2015; Raghuwanshi & Pateriya, 2019).

Lops et al. (2011) argumentan que el filtrado colaborativo basado en modelos aplica principalmente técnicas de reducción de dimensionalidad, como el *Principal Component Analysis* (PCA) o la *Singular Value Decomposition* (SVD), el *Clustering*, los *Decision Trees* (DT), o las *Deep Neural Networks* (DNN).

3.4.2. Filtrado por Contenido

Los sistemas de recomendación de filtrado por contenido (*Content-Based Filtering*, CBF) se distinguen por ofrecer al usuario sugerencias de artículos similares a aquellos que le han resultado interesantes en el pasado, emparejando las características del perfil del usuario y las de los productos, guiándose por sus descripciones y metadatos (Lops et al., 2011). Así, se obtienen recomendaciones por comparación entre atributos que definen al consumidor y al artículo en cuestión. El resultado es un indicador de relevancia que expresa el interés del usuario en dicho producto. Ricci et al. (2015) y Lops et al. (2011) explican el **proceso de recomendación** se desarrolla en tres pasos:

- 1) Analizador de contenido (*content analyzer*): procesa la información de entrada y extrae los atributos presentes en la descripción de los productos.
- 2) Generador de perfil (*profile learner*): construye el perfil del usuario utilizando algoritmos de *Machine Learning* basados en sus preferencias.
- 3) Componente de filtrado (*filtering component*): compara el perfil del usuario con los atributos de los productos para recomendar los más relevantes (Thorat et al., 2015).

El proceso se repite **iterativamente**, ajustándose según el *feedback* del usuario, como valoraciones o reseñas (Thorat et al., 2015). La metodología se apoya en el análisis del lenguaje

natural (NLP) que consiste en interpretar semánticamente la información asociada a los atributos para dotarla de sentido (Lops et al., 2011). Este ciclo repetitivo es vital, pues las preferencias del usuario pueden cambiar a lo largo del tiempo. El filtrado basado en contenido se emplea construyendo modelos probabilísticos (Naïve Bayes y Support Vector Machines), modelos basados en el *feedback* (Algoritmo de Rocchio) y otros como los k-Vecinos más Próximos, o la clasificación lineal.

Los sistemas de filtrado por contenido ofrecen ventajas como la independencia de los perfiles de usuarios, la facilidad para justificar recomendaciones y la capacidad de sugerir artículos sin reseñas previas. No obstante, presentan desventajas como la sobrespecialización, la dificultad para generar recomendaciones a nuevos usuarios sin suficientes datos, y problemas relacionados con la interpretación léxica, como sinonimias o polisemia (Lops et al., 2011; Ricci et al., 2015).

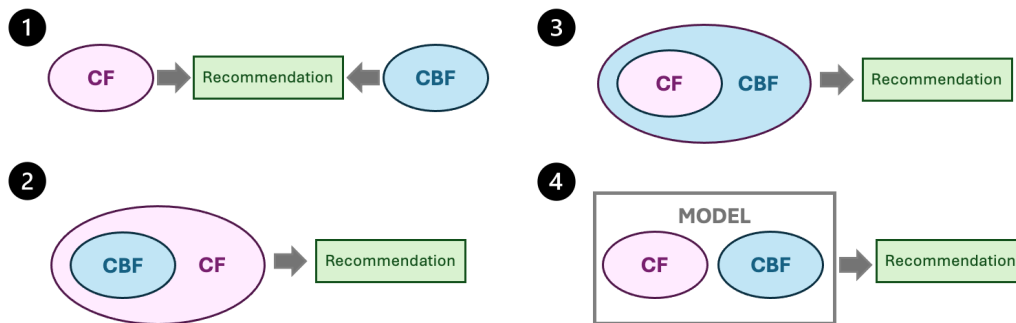
3.4.3. Sistemas Híbridos

Los sistemas híbridos son aquellos que combinan ambos tipos de filtrado, colaborativo (CF) y basado en contenido (CBF), con el fin de mejorar la precisión de las recomendaciones y solucionar los problemas a los que se enfrentan cada una de las técnicas de filtrado individualmente (Trabelsi et al., 2021; Khusro et al., 2016; Thorat et al., 2015). Trabelsi et al. (2021) sostienen que ambos modos de filtrado son complementarios, pues mientras que el filtrado colaborativo sufre del problema de arranque en frío, el filtrado por contenido es capaz de generar recomendaciones aun cuando no se dispone de valoraciones. No sólo eso, sino que también pueden combinar varios algoritmos de *Machine Learning* para lograr un mayor rendimiento.

La **Figura 10** recoge a modo de diagrama los cuatro **modelos** posibles (Thorat et al., 2015) en que se pueden implementar los sistemas híbridos:

- 1) Aplicar filtrado colaborativo y filtrado basado en contenido por separado, y agregar los resultados de ambos. En este caso, las recomendaciones resultantes se distinguen por ser mucho más precisas.
- 2) Integrar algunas de las características de filtrado basado en contenido en sistemas de filtrado colaborativo.
- 3) Integrar algunas de las características de filtrado colaborativo en sistemas de filtrado basado en contenido.
- 4) Construir desde cero un modelo integrando ambos tipos de filtrado. Es el modo más costoso, pero sirve para fomentar la efectividad del proceso de recomendación.

Figura 10: Modelos de implementación de los sistemas de recomendación híbridos.



Fuente: Elaboración propia (2024)

3.5. Desafíos y Áreas de Investigación

A pesar del gran valor añadido que ofrecen tanto a usuarios como a fabricantes, los sistemas de recomendación se enfrentan a varios **desafíos** como la falta de datos o la diversidad de las sugerencias. A continuación, se enumeran los más comunes:

- **Problema de arranque en frío o *cold start problem*:** se produce cuando se incluyen nuevos artículos o usuarios a la plataforma. En este supuesto es imposible predecir tanto las reseñas que tendrá el producto, como los gustos del consumidor, por lo que las recomendaciones son poco precisas (Thorat et al., 2015; Ricci et al., 2015).
- **Sinonimia o *synonymy*:** se asocia a la ambigüedad en la interpretación del lenguaje natural (NLP) y suele darse cuando existen varias palabras con significados parecidos o cuando se utilizan frases hechas. Suele ocurrir en sistemas de filtrado basado en contenido.
- **Ataques de manipulación o *shilling attacks*:** se refiere a la manipulación de valoraciones que puede afectar gravemente a las recomendaciones y a la confianza que el usuario deposita en el sistema (He et al., 2017).
- **Falta de serendipia y sobrespecialización o *lack of serendipity and overspecialization*:** en tanto que el algoritmo se va perfeccionando tanto, que falla en detectar nuevos productos que podrían ser de interés. La serendipia se define como la capacidad que tienen los sistemas de recomendación de ayudar al usuario a encontrar innovadores productos que satisfacen igual de bien sus necesidades (Trabelsi et al., 2021; Ricci et al., 2015).
- **Ovejas grises o *grey sheep*:** ocurre en aquellos sistemas de filtrado colaborativo en los que resulta difícil realizar recomendaciones a usuarios con preferencias y opiniones muy particulares al no encajar en ninguno de los segmentos contemplados (He et al., 2017).

- Escasez de datos o *data sparsity*: sucede cuando se tienen muchos productos y usuarios, pero poca información sobre ellos, por lo que puede desembocar en problemas de arranque en frío (Lops et al., 2011).
- Escalabilidad o *scalability*: se produce cuando se tiene una infinidad de productos y usuarios que es complejo determinar las mejores recomendaciones.
- Latencia o *latency*: surge en plataformas que sufren de retrasos a la hora de generar recomendaciones debido al alto número de artículos disponibles y al gran esfuerzo computacional (Bobadilla et al., 2020).
- Sensibilidad al contexto o *context-awareness*: la falta de información contextual puede afectar negativamente a la precisión de las recomendaciones, sobre todo en situaciones especiales en donde las preferencias a corto plazo del usuario difieren de las habituales (Thorat et al., 2015).

Si bien, los desafíos anteriores han impulsado la investigación de nuevas oportunidades para mejorar la eficiencia de las recomendaciones. De este modo, las **tendencias actuales de investigación** son las siguientes:

- Analizar las valoraciones negativas implícitas de otros usuarios, como las devoluciones de productos, para filtrar mejor los artículos sugeridos (Bobadilla et al., 2020).
- Estudiar en detalle el porqué de dichas recomendaciones de cara a justificar su presentación al cliente, mejorando la transparencia asociada al *modus operandi* del algoritmo y, consecuentemente, inspirando una mayor confianza (He et al., 2017).
- Optimizar la gestión de ofertas y promociones determinando el umbral de sensibilidad que cada usuario tiene en materia de precio para cada producto, y gestionando su disponibilidad (Schafer et al., 1999).
- Integrar las recomendaciones cruzadas de productos de diferentes sectores, aprovechando para ello los datos del usuario en otras plataformas e incorporándolos en el *marketplace* en cuestión, alcanzando una mayor personalización si cabe (Trabelsi et al., 2021).
- Insistir en la importancia de recabar la información demográfica y social básica de cada consumidor para mejorar la calidad de las recomendaciones (Thorat et al., 2015).
- Analizar cómo se puede incorporar en estos sistemas el contexto temporal y las circunstancias psicológicas del sujeto, para poder adaptar las recomendaciones a su estado anímico, a su personalidad o a una situación en particular (Lops et al., 2011).

- Explotar la recopilación de datos implícitamente por medio de la dirección IP del usuario, conocer su ubicación exacta y el dispositivo que usa para navegar (Khusro et al., 2016).
- Perfeccionar las técnicas de filtrado para fomentar la serendipia, eliminando los artículos obsoletos y recomendando los novedosos. He et al. (2017) subrayan que se trata de obtener un balance entre “viejo” y “nuevo”.
- Enfatizar la necesidad de almacenar datos que se refieran tanto a las preferencias a largo plazo del usuario, como a las más circunstanciales, con el objetivo de entender mejor su comportamiento y estudiar patrones de consumo (Bobadilla et al., 2020).

3.6. Impacto en el Comportamiento del Consumidor

Los sistemas de recomendación han transformado el comercio *online*, personalizando la experiencia de compra y afectando profundamente el comportamiento de los consumidores. Al mejorar el *engagement* y facilitar la toma de decisiones, estos sistemas responden a la demanda de los usuarios de experiencias más ágiles, impulsadas por la tecnología móvil y plataformas intuitivas. Además de atraer nuevos consumidores, **la personalización incrementa la satisfacción y la intención de compra**. Según un estudio de ChoiceStream (2008), el 45% de los usuarios prefieren sitios que emplean sistemas de recomendación personalizados (Pu et al., 2012).

Los sistemas de recomendación no solo facilitan las compras *online*, sino que aumentan la satisfacción del cliente al proporcionar una experiencia personalizada e inmersiva. En un entorno saturado de información, Babatunde et al. (2024) destacan la importancia de captar la atención del consumidor es esencial, y cómo estas herramientas influyen directamente en sus decisiones de compra al ofrecer productos alineados con sus intereses. Además, los consumidores que buscan una relación más profunda con el fabricante suelen desarrollar una conexión y **fidelización** mayor hacia la plataforma, lo que refuerza el vínculo a largo plazo con la marca (Bozkurt Ates & Odzic, 2023).

La personalización es clave para fortalecer la relación entre consumidores y marcas. Herramientas de Inteligencia Artificial, como las que usan Procesamiento del Lenguaje Natural (NLP), permiten a los *marketplaces* ajustar la comunicación en tiempo real, maximizando el *engagement*. Los algoritmos de *Machine Learning* no solo predicen qué productos interesan al usuario, sino también cuándo presentarlos para optimizar la experiencia de compra (Raji et al., 2024). Además, según Jannach & Adomavicius (2016), los consumidores valoran los sistemas que consideran su contexto o situación, ofreciendo recomendaciones relevantes en el momento oportuno.

Aparte de ajustar la comunicación en tiempo real y maximizar el *engagement*, el marketing personalizado crea en los consumidores una sensación de comprensión y valoración, lo cual fomenta el éxito de las marcas a largo plazo (Babatunde et al., 2024). Teorías como el Modelo de Probabilidad de Elaboración (ELM), la Teoría de Usos y Gratificaciones (UGT) y la Teoría Cognitiva Social (SCT) subrayan cómo la personalización profundiza los pensamientos del consumidor, incrementa el *engagement* y refuerza la toma de decisiones basadas en el entorno social. Xiao & Benbasat (2007) afirman que esta personalización mejora la **segmentación** de los consumidores, aumentando la satisfacción, lealtad y la percepción de marca.

Pu et al. (2012) argumentan que los sistemas de recomendación facilitan el proceso de compra al ajustar las sugerencias según las preferencias del usuario, lo que **reduce el esfuerzo cognitivo** y aumenta la satisfacción. Los consumidores valoran la facilidad de uso y prefieren sistemas que requieran menos *input* por su parte. Los sistemas de recomendación limitan las alternativas procesadas, mejorando la calidad de las decisiones. Los sistemas híbridos son más precisos, pero requieren más input, mientras que los compensatorios y basados en necesidades también mejoran la calidad de las decisiones y satisfacción, aunque implican mayor esfuerzo. Un exceso de opciones puede reducir la calidad de la decisión (Xiao & Benbasat, 2007; Jannach & Adomavicius, 2016).

La integración de *chatbots* y asistentes virtuales ha mejorado la atención al cliente al ofrecer respuestas en tiempo real, lo que facilita tanto la toma de decisiones como el recorrido del cliente. Estas herramientas ayudan a los usuarios a descubrir productos más ajustados a sus preferencias, lo que incrementa las **tasas de conversión** y la satisfacción general del cliente, al reducir el tiempo y esfuerzo necesarios para encontrar lo que buscan (Babatunde et al., 2024).

Las **experiencias de compra previas** tienen un impacto significativo en la satisfacción, el *engagement* y la lealtad a largo plazo de los usuarios. Estas experiencias, junto con las nuevas tecnologías, influyen directamente en el comportamiento del consumidor, mejorando las actitudes hacia las recomendaciones personalizadas y las intenciones de compra (Bozkurt Ates & Odzic, 2023). Las buenas experiencias generan confianza y reducen los riesgos percibidos en las compras *online*, motivando a los consumidores a seguir comprando. Xiao & Benbasat (2007) recalcan que comprender la relación entre estas actitudes y las intenciones de compra requiere examinar las experiencias previas, ya que son determinantes clave en la **confianza** hacia los sistemas de recomendación.

Una actitud favorable hacia las compras virtuales influye directamente en el uso de plataformas de *e-commerce*, especialmente si los consumidores confían en las **tecnologías** empleadas. A

medida que esta confianza aumenta, las decisiones de compra se ven influenciadas positivamente, mejorando la efectividad de las recomendaciones personalizadas y aumentando la probabilidad de compra (Raji et al., 2024). Las percepciones del sistema y del fabricante juegan un papel crucial en esta confianza. Además, la experiencia de compra incluye no solo la transacción, sino también las emociones y percepciones generadas durante el proceso.

Adaptar el proceso de recopilación de preferencias a las características del usuario, como su nivel de conocimiento, o proporcionar métodos más visuales y entretenidos aumenta la participación del usuario (Pu et al., 2012). Los sistemas que consideran la **personalidad** mediante cuestionarios, en lugar de solo solicitar valoraciones de productos, reducen la fatiga cognitiva y resultan más satisfactorios. El método de **elicitación explícita** mejora la calidad de las decisiones en comparación con la implícita, aunque requiere mayor esfuerzo. Autores como Jannach & Adomavicius (2016) puntualizan que, además, dar al usuario control sobre la interfaz de preferencias incrementa su confianza, satisfacción y percepción de utilidad del sistema de recomendaciones.

Las **reseñas y valoraciones de otros usuarios** influyen en la percepción de los productos recomendados, ya sea de manera positiva, aceptando las opiniones mayoritarias, o negativa, percibiéndolas como manipuladas. La presentación de estas recomendaciones afecta la confianza del usuario en el fabricante y la precisión del sistema. Los atributos de producto que aparecen en la interfaz del sistema de recomendación tienen un peso significativo en la toma de decisiones, y los productos con mejores puntuaciones o calificaciones predichas son evaluados de manera más favorable y elegidos con mayor frecuencia (Xiao & Benbasat, 2007).

El **tipo de producto** también es determinante. Los productos de experiencia tienden a influir más en la elección del usuario que los productos de búsqueda, y la complejidad del producto mejora la calidad de las decisiones y reduce el esfuerzo de decisión con sistemas de recomendación. Los usuarios confían más en los sistemas de recomendación para productos de experiencia y valoran más la utilidad de estos sistemas para productos de búsqueda (Bozkurt Ates & Odzic, 2023). Además, según Raji et al. (2024) la credibilidad del proveedor y la reputación del mismo influyen en la confianza depositada en los sistemas de recomendación, siendo los sitios de terceros más confiables que proveedores desconocidos o menos reputados.

Los usuarios perciben las recomendaciones como un conjunto completo, evaluando cómo este se ajusta a sus preferencias, y valoran un equilibrio entre productos populares y personalizados. Sin embargo, una excesiva diversificación en las sugerencias puede reducir la percepción de calidad. Cuando el sistema recomienda productos ya comprados, los usuarios confían más en él. Para ser

eficaz, el sistema debe **equilibrar entre sugerencias conocidas y novedosas** (Pu et al., 2012). Además, proporcionar información detallada sobre los productos y cómo se generan las recomendaciones aumenta la confianza, satisfacción y lealtad del usuario hacia la plataforma Jannach & Adomavicius, 2016).

La **presentación de las recomendaciones** es crucial para influir en las decisiones de compra. Un sistema preciso genera confianza, incentivando el uso recurrente, aunque la percepción de precisión varía entre usuarios. Un formato claro y bien estructurado facilita la navegación, mejorando la satisfacción. Las listas ordenadas ayudan a optimizar la toma de decisiones. Adicionalmente, Xiao & Benbasat (2007) explican cómo los usuarios confían más en los sistemas que perciben bien ajustados a sus preferencias, lo que refuerza tanto la confianza como la utilidad percibida del sistema.

Permitir que los usuarios proporcionen valoraciones sobre los productos que elijan les genera una mayor **sensación de control**, motivándolos a interactuar más con la plataforma. Además, el control sobre las características que influyen en las recomendaciones reduce el riesgo percibido y mejora la confianza. Hacerles conscientes del **impacto de sus contribuciones** dentro de la comunidad fomenta actitudes positivas hacia la plataforma (Bozkurt Ates & Odzic, 2023). Recompensas por sus acciones, como descuentos por reseñas, refuerzan el compromiso y participación, creando un ciclo de retroalimentación positivo que aumenta la satisfacción y la disposición a proporcionar más *feedback* (Babatunde et al., 2024).

En conclusión, los sistemas de recomendación personalizados mejoran la percepción de calidad del usuario, aumentando la satisfacción y efectividad percibida en la toma de decisiones. La facilidad para generar nuevas recomendaciones fortalece la confianza y satisfacción de los usuarios. De acuerdo con Bozkurt Ates & Odzic (2023) estos sistemas operan en un **ciclo de "entender, ofrecer, medir"**, creando fidelización y aumentando la confianza del consumidor. Además de atraer nuevos clientes, los sistemas de recomendación son clave para retener a los existentes, mejorando el *engagement* y la lealtad. Su implementación eficaz requiere aprendizaje continuo y experimentación constante para destacar en el mercado.

CAPÍTULO IV: El Caso de Amazon

En este capítulo se presenta el caso de estudio del trabajo, basado en los sistemas de recomendación de Amazon. En primer lugar, se introducirá brevemente la empresa y se abordarán sus estrategias de personalización asociadas a las recomendaciones. A continuación, se explicarán los objetivos y la metodología seguida a la hora de diseñar el cuestionario, para finalmente discutir los resultados y plantear una serie de oportunidades, además de identificar áreas de mejora.

4.1. Contextualización del Caso de Estudio

Desde su concepción en como una gran **librería online**, Amazon ha experimentado constantes cambios hasta convertirse en el fenómeno del *e-commerce* y la computación en la nube que conocemos hoy en día. Sus orígenes se remontan a 1994, cuando su fundador Jeff Bezos entendió el potencial de Internet, una tecnología que crecía por aquel entonces a una tasa anual del 2300% (Sadq et al., 2018; Imaeka & Uford, 2023). Así pues, se propuso crear una plataforma que permitiría a sus usuarios descargar miles de libros desde una única interfaz.


Según Ritala et al. (2014), el éxito de la plataforma y los avances de la web, empujaron a Bezos a adoptar una estrategia de crecimiento rápido (“*get big fast*”) con el fin de ganar tanto una cuota de mercado considerable, como una sólida base de clientes. La estrategia giraba en torno a la idea de crear una plataforma centrada en el consumidor donde éste pudiera encontrar fácilmente todo cuanto deseara (Imaeka & Uford, 2023). Así fue como, en junio de 1998, Amazon comenzó a diversificar su oferta y comercializar DVDs, música y vídeos, expandiendo también su alcance al abrir nuevos mercados en Reino Unido y Alemania (Sadq et al., 2018).

Con el auge de Internet, llegó en la creación del **Amazon Marketplace** en noviembre del año 2000, donde la empresa permitía a terceros ofertar sus productos dentro de la plataforma. Ritala et al. (2014) subrayan este hecho como el comienzo de un modelo de negocio basado en la “*coopetition*”, más tarde bautizado por Bezos como la “*single store strategy*”, en la dominaba el enfoque en el consumidor, más que en la competencia. A pesar del temor de que la oferta de Amazon fuera canibalizada por otras compañías y de la repentina caída en bolsa de la empresa, Bezos defendió que el valor añadido que la empresa proporcionaba al consumidor procedía precisamente de las sinergias con esos vendedores. Del mismo modo, la amplia oferta se traduciría

en un aumento de la satisfacción del usuario, del que se beneficiarían tanto el propio *marketplace* como el fabricante, tal y como reconoció al periódico *The Economist* (2012).

Hoy en día, Amazon ha extendido su oferta de prestaciones a fabricantes y desarrolladores web, con servicios como el *Fulfillment by Amazon* (FBA) o el *Amazon Web Services* (AWS), y cuenta con más de 310 millones de clientes en todo el mundo, procedentes de más de 180 países (eDesk, 2024; Adisman, 2023). En su informe anual de 2023, la compañía reporta unos ingresos de 575.000 millones de dólares, un aumento de un 12% respecto al año anterior debido al crecimiento registrado en todos sus segmentos y mercados emergentes como Brasil, Australia o México. Y es que de acuerdo con la **Figura 11**, tan sólo en España, Amazon se posiciona como el *marketplace* **líder en comercio B2C** con una tasa de penetración entre los consumidores del 90%.

Figura 11: Ranking de marketplaces online con mayor tasa de penetración entre los consumidores en España en 2023.



Fuente: Statista (2023)

Para Imaeka & Uford (2023), las **claves del éxito** de la empresa residen en cinco aspectos clave:

- 1) La reputación de la marca, que repercute directamente sobre la valoración de la empresa, estimada en 1.570,15 mil millones de dólares a finales de 2023 (Stock Analysis, s.f.). Además, según Mellahi & Johnson (2000), Amazon destinaría el 40% de sus ingresos en construir y reforzar la imagen de la marca.
- 2) La constante innovación que puede observarse en sus intentos de diferenciación, siendo la primera compañía en implementar el “*one-click*” para acelerar el proceso de compra, incluir las suscripciones a Amazon Prime, permitir la comparación de productos y utilizar el filtrado colaborativo.

- 3) El enfoque centrado en el consumidor que facilita el proceso de compra adapta las sugerencias al perfil del usuario y le customiza los precios de manera dinámica. Con esto, se logra fidelizar al cliente y fomentar sucesivas compras (Sadq et al., 2018), permitiendo que la empresa prevea de manera eficiente la demanda (Mellahi & Johnson, 2000).
- 4) La gran infraestructura logística, la reducción de los tiempos de entrega y los acuerdos de almacenaje y envío con los fabricantes que figuran en la plataforma. En esta línea, Sadq et al. (2018) destacan su capacidad para aprovecharse de las economías de escala.
- 5) El crecimiento explosivo que ha experimentado el comercio *online* a raíz de la pandemia de la COVID-19. Las cuarentenas y el confinamiento impulsaron las ventas de Amazon, que llegó a doblar sus ganancias de 2019 a 2020 (Mena Roa, 2021).

4.2. Las Estrategias de Personalización de Amazon

Desde 1998, la obsesión de Amazon por sus clientes ha estado presente en sus estrategias de negocio que tenían por objetivo convertir a **la empresa en la más centrada en el cliente del mundo** (Ritala et al., 2014), lema que aún mantiene como misión (Amazon, s.f.). Sin embargo, no se puede decir lo mismo de las prioridades de los consumidores, que han ido evolucionando con el tiempo desde el precio, hasta la agilidad, pasando por la calidad y flexibilidad. Hoy en día, el cliente no se conforma con alguna de ellas, sino que quiere las cuatro a la vez (Kumar, 2008).

Una forma de cumplir con estas exigencias es a través de la **personalización**, que no es más que una estrategia de diferenciación que se centra en el individuo más allá de la customización por segmentos. Según Lindecrantz et al., (2020), actualmente, el 80% de los consumidores reclama la implementación de herramientas de personalización en los *e-commerce*. Ya lo argumentó Joe Pine en su libro “*Mass Customization*” (1993), en donde expresaba la necesidad de las empresas de desarrollar miles de productos para cubrir las miles de necesidades de sus miles de clientes, desplazando la filosofía clásica de la estandarización pura por una personalización absoluta. Lo mismo predecía el propio Jeff Bezos en su carta a los accionistas (1997) en donde mencionaba: “Hoy, el comercio en línea ahorra a los clientes un dinero y un tiempo valiosos. Mañana, a través de la personalización, el comercio en línea acelerará el propio proceso de descubrimiento.”

Para Bezos, la innovación venía de la mano de la personalización, y a su vez, la personalización era inherente a la era digital. Esta realidad dio lugar al primer **algoritmo de recomendación** de Amazon en 1998, cuando aún era meramente una librería online (Smith & Linden, 2017). Y es que medida que fue diversificando su oferta, Bezos cayó en la cuenta de que, si tenía dos millones

de clientes, tenía que tener dos millones de tiendas distintas (Schafer et al., 1999). Así, su sistema de recomendación generaría sugerencias de artículos de programación a ingenieros de software y sugerencias de juguetes a una madre primeriza (Linden et al., 2003).

Amazon utiliza el **filtrado colaborativo basado en artículos** debido a su escalabilidad, a la diversidad de sus recomendaciones y a la explicabilidad de cara a los usuarios (Smith & Linden, 2017). Para ello, emplea técnicas de minería de datos con el fin de recopilar información sobre el historial de compras y navegación, la demografía, las valoraciones realizadas por el usuario y sus gustos hasta elaborar el perfil del consumidor (Kumar, 2008). Así pues, las recomendaciones se realizan teniendo en cuenta únicamente las compras previas del cliente, lo que reduce el esfuerzo computacional que, en su mayoría se realiza *offline*, y mejora la optimización de las sugerencias en tiempo real según el usuario vaya interactuando con el sistema (Linden et al., 2003). Smith & Linden (2017) indican que el problema del arranque en frío se resuelve recomendando los productos más populares hasta reunir suficientes datos sobre el usuario como para ofrecerle recomendaciones personalizadas.

El desarrollo de los algoritmos de *Machine Learning* junto con los avances de los servicios de computación en la nube de Amazon (AWS), resultaron en un nuevo sistema de recomendación, conocido como **A10** (Bouguezzi, 2024). Este algoritmo es el secreto mejor guardado de la empresa y fue inventado a causa de la inmensidad de datos que ha de manejar (Linden et al., 2003). El A10 ha implicado no sólo una mejora significativa frente a los sistemas convencionales, sino que ha supuesto el salto de toda una década de acuerdo con Jeff Wilke, CEO de la división de consumo de Amazon (Hardesty, 2019). El funcionamiento del sistema se basa en cuatro etapas: interpretar las búsquedas del usuario mediante NLP, procesar los resultados y ordenarlos según su relevancia, medir el *engagement* mediante la tasa de conversión (CR) o los *clicks* (CTR), y adaptar inmediatamente las sugerencias en consecuencia. Asimismo, Amazon lleva a cabo tests tipo A/B para evaluar cómo reaccionan los consumidores a diferentes aspectos como la presentación de las sugerencias (Hardesty, 2019).

No obstante, hasta llegar al A10, Smith & Linden (2017) afirman que Amazon ha concentrado sus esfuerzos en definir qué es la similitud entre productos de cara a proporcionar recomendaciones más ajustadas y resolver los conflictos que trae consigo. Uno de ellos, en materia de compatibilidad, ya que a veces el sistema podría sugerir productos que no sean compatibles como, por ejemplo: una cámara digital y una tarjeta de memoria. Otros **desafíos** a los que se enfrenta serían distinguir procesos de compra secuenciales, cuando el cliente compra artículos relacionados en un corto periodo de tiempo, o la intencionalidad del usuario, de tal forma que si únicamente está navegando por la plataforma las sugerencias se planteen con el fin de que

pueda descubrir nuevos artículos, mientras que, si está buscando algo más concreto, las recomendaciones sean focalizadas.

Hardesty (2019) destaca cómo, a lo largo de los años, la compañía ha tratado de **mejorar el sistema de recomendación** aplicando métodos de factorización de matrices como el SVD y las redes neuronales profundas, usando *autoencoders*⁵ y fijando un margen temporal previo a la generación de las recomendaciones para encontrar la combinación perfecta entre productos similares a los ya comprados y productos novedosos. A pesar de ello, el filtrado colaborativo basado en artículos demostró ser más efectivo y preciso en sus recomendaciones, tanto, que un estudio realizado por McKenzie et al. (2013) atribuye el 35% de las ventas de Amazon a dichas recomendaciones. En ocasiones, la empresa aplica también sistemas híbridos una primera fase de filtrado colaborativo basado en artículos y una segunda de filtrado colaborativo basado en contenido para emparejar características específicas del producto con el perfil del consumidor (Bouguezzi, 2024).

En concreto, Gorgoglione et al. (2019) y Smith & Linden (2017) recogen que las estrategias de personalización de Amazon se llevan a cabo tanto *on-site* como *off-site*:

a) *On-site* en el propio *marketplace* en distintas pestañas y secciones:

- En la página de inicio: aparecen recomendaciones ordenadas por categoría de producto, “sigue comprando” productos que has visto recientemente, o “descubre grandes ofertas”, entre otras.
- En la pestaña de “Amazon.com del usuario”: aquí aparecen “recomendaciones para ti”, “tu historial de búsqueda”, “comprarlo de nuevo”, “los clientes que han visto productos que aparecen en tu historial de búsqueda también han visto”. Son recomendaciones basadas en el historial y las preferencias del usuario.
- En la pestaña de “volver a comprar”: en forma de “compras anteriores” y “similares a tus compras anteriores”.
- Cuando accedes a ver un producto: figuran sugerencias como “comprados en conjunto habitualmente”, “productos relacionados con este producto” y “descubre productos

⁵ Un *autoencoder* o *autocodificador* es un tipo de arquitectura presente en redes neuronales que permite extraer las características más significativas de los datos, por lo que agiliza el tratamiento de la información (Bergmann & Stryker, 2023).

similares” cuyo objetivo es el de aumentar la venta cruzada recomendando artículos parecidos o complementarios.

- En la cesta antes de tramitar el pedido: son recomendaciones como “comprarlo de nuevo”, “inspirado en tu historial de búsqueda” y “guardados para después”, que son aquellos productos en los que ha mostrado interés el usuario. El fin de éstas es aumentar tanto la venta cruzada, como el valor total de la compra.
 - En el agradecimiento tras una compra: en forma de “quizás te interese” o “sigue comprando...”. En esta etapa, se estima que la probabilidad de vender al cliente que recién ha tramitado su compra es del 60% o 70% (Parker, 2022).
 - Pestaña de tendencias: se presentan sugerencias bajo “los más vendidos”, “últimas novedades” y “productos del momento”. Sin embargo, estas no son personalizadas, sino que se basan en el interés popular.
- b) *Off-site* en forma de correos electrónicos** con “los artículos más vendidos de esta semana”, “sigue comprando...”, “los más vendidos en una categoría de producto” sobre la que el usuario ha mostrado interés, y “ofertas Prime” si se trata de un cliente suscrito. Por tanto, las sugerencias aquí pueden ser personalizadas y no personalizadas. Arsenault (2021) apunta a que esta modalidad es más efectiva, con una tasa de conversión mayor que con las recomendaciones *on-site*, cercana al 60%.

No obstante, Amazon no sólo se limita a proporcionar al consumidor con recomendaciones personalizadas, sino que lleva a cabo otras iniciativas como publicidad dirigida en páginas consultadas por el usuario, promociones y discriminación de precios en tiempo real y **notificaciones *push*** a través del navegador *web* (Retta, s.f.). Además, la empresa facilita el proceso de compra con el ***one-click checkout***, con el cual el usuario no necesita volver a introducir todos los detalles del pago cada vez que realiza una compra, sino que se puede despreocupar ya que éstos quedan registrados (Mellahi & Johnson, 2000). Este detalle es clave en un entorno en el que el 18% del 70% de los carritos de compra que son abandonados se debe al largo procedimiento de pago *online* (Rebuy, 2022).

4.3. Estudio sobre las Percepciones de los Consumidores de Amazon sobre sus Sistemas de Recomendación

Una vez analizados los sistemas de recomendación de Amazon y sus estrategias de personalización, es esencial estudiar el impacto que tienen los distintos tipos de recomendaciones sobre los consumidores, evaluando las percepciones que tienen sobre su utilidad y relevancia, así como identificando áreas de mejora. Para ello, se llevó a cabo un estudio cuantitativo a través de una encuesta mediante cuestionario diseñado en Google Forms.

La **elección de esta técnica** se justifica en que es un método ampliamente utilizado en investigación de mercados por ser capaz de arrojar datos estandarizados y estructurados, con lo que además facilita su posterior procesamiento. Frente a otros métodos, la encuesta destaca porque permite obtener cierta uniformidad en las respuestas a través de preguntas cerradas de opción múltiple o de escala de Likert entre otras (Bryman, 2016). Además, es una técnica sencilla, económica, fácilmente accesible y muy eficiente para análisis exploratorios (Saunders et al., 2019).

En este caso, ha llevado a cabo una **encuesta mediante cuestionario *online* y autoadministrado**, cuya modalidad se adapta a las necesidades del estudio por varias razones. Primeramente, los cuestionarios *online* permiten alcanzar a un gran número de participantes de manera eficiente y gratuita, por lo que son adecuados en estudios como este, donde el tiempo y los recursos son limitados (Etikan et al., 2016; Saunders et al., 2019). De esta forma, los cuestionarios *online* facilitan la recopilación de datos y su posterior tratamiento en hojas de cálculo a la hora de llevar a cabo el análisis estadístico de los resultados. Asimismo, al tratarse de un cuestionario autoadministrado, se reduce el sesgo que introduce la presencia del investigador, que no es capaz de juzgar en directo las respuestas de los encuestados, a diferencia de los *focus groups* o entrevistas personales, al tiempo que se le concede la libertad de rellenarlo cuando mejor le convenga (Bryman, 2016).

Una vez definida la técnica, se procedió a determinar la población objetivo y el muestreo empleado. La **población objetivo** comprendía aquellos consumidores actuales de Amazon en España independientemente de su edad y situación laboral. El muestreo empleado fue **no probabilístico**, ya que el cuestionario se distribuyó en un inicio por redes sociales, específicamente a través de WhatsApp, en donde los individuos fueron seleccionados por conveniencia. También se aplicó el muestreo de **bola de nieve**, pidiendo a los encuestados que distribuyeran el cuestionario a sus respectivos contactos. La justificación para introducir el muestreo por bola de nieve reside en que es muy útil en situaciones en donde la población objetivo

no está delimitada a un grupo pequeño, ya que permite que la muestra vaya creciendo progresivamente sin necesidad de ser supervisada por el investigador (Biernacki & Waldorf, 1981).

Con el fin de garantizar que efectivamente sólo respondía el cuestionario la población objetivo, se incluyó una **pregunta de tipo filtro**, en la cual se preguntaba si eran o no clientes de Amazon. Además, antes de comenzar con el cuestionario se recogieron estas **variables de clasificación** para poder conocer el perfil de los encuestados y ver si sus características sociodemográficas afectarían de alguna forma a sus percepciones sobre las recomendaciones.

El cuestionario se estructuró en varias secciones, empezando por un análisis exploratorio de los hábitos de compra, seguido del estudio sobre la percepción de las recomendaciones, hasta llegar a evaluar el interés en ciertas iniciativas innovadoras. El final del cuestionario contiene varias preguntas de control para validar la consistencia de las respuestas y velar por la calidad de los datos recopilados. El *Anexo I* contiene el cuestionario final **distribuido entre el 19 y el 24 de noviembre**, donde se puede apreciar que se formularon **preguntas de distintos tipos**, entre las que destacan: preguntas cerradas, de opción múltiple, de escala numérica o incluso de escala de Likert.

En ese período, se registraron un total de 121 respuestas, de las que, debido a la pregunta tipo filtro, sólo 105 eran válidas. Tras cerrar el cuestionario, se procedió al **tratamiento de los datos recopilados**, representando gráficamente los resultados en Excel, así como las tablas de frecuencia estadística, con el fin de poder analizarlos en su conjunto y extraer las conclusiones que se presentan en los siguientes epígrafes.

4.4. Análisis de Resultados

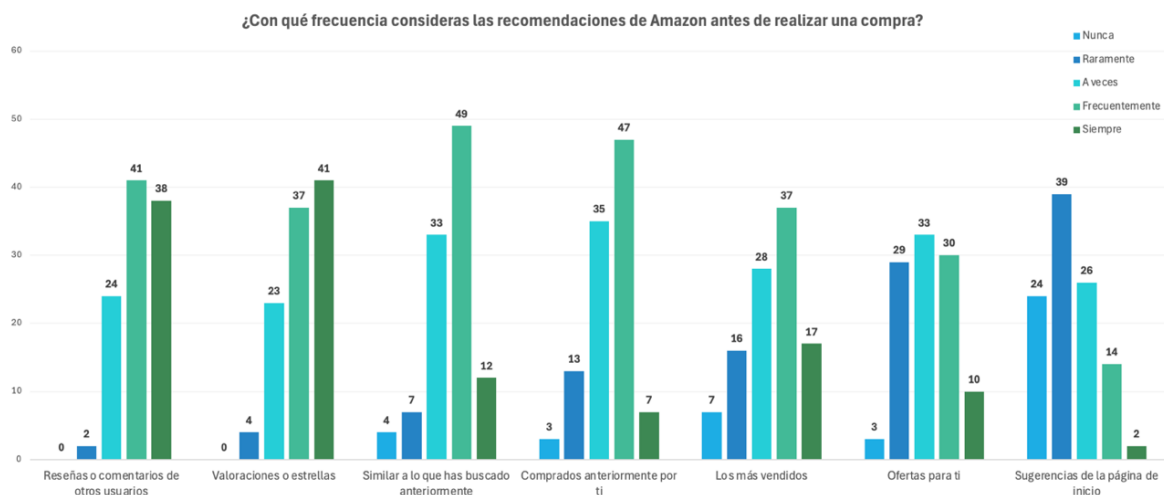
Una vez recopiladas las respuestas y tratados los datos, es posible llevar a cabo el análisis de los resultados obtenidos. Las representaciones estadísticas de las respuestas pueden consultarse en el *Anexo II*, a continuación del cuestionario. No obstante, y como ya se mencionó anteriormente, la tercera pregunta hizo de filtro para eliminar del estudio a aquellos usuarios que no eran clientes de Amazon. Por tanto, de las 121 respuestas iniciales, 16 fueron filtradas, por lo que finalmente se tuvieron **105 respuestas válidas**.

En primer lugar, en cuanto al **perfil de los encuestados**, la mayoría se encuentra en el rango de edad de 25 a 34 años (27%), seguido muy de cerca por el grupo de 45 a 54 años de edad (25%). En términos de ocupación, el 71% de los encuestados son trabajadores, el 19% estudiantes, y tan

sólo el 10% están actualmente en paro o jubilados. Respecto a la frecuencia de compra en Amazon, la tendencia popular es bien, comprar una vez al mes (33%) o bien, ocasionalmente cada 3 o 6 meses (32%), por lo que se trata de usuarios relativamente activos en la plataforma. De hecho, en su interacción con ella, el **82% de los individuos admitió haber comprado en algún momento productos recomendados por Amazon**. Este hallazgo, ya de primeras, apunta a que muchos de los usuarios confían en las recomendaciones como parte de su experiencia de compra.

Las preguntas n.º 6, 7 y 8 del cuestionario estaban orientadas a estudiar el **impacto** que tienen sobre los consumidores de Amazon cada uno de los siguientes tipos de recomendaciones: reseñas o comentarios, valoraciones o estrellas, “similar a lo que has buscado anteriormente”, “comprados anteriormente por ti”, los más vendidos, “ofertas para ti” y sugerencias de la página de inicio.

Figura 12: Frecuencia con la que los consumidores de Amazon encuestados consideran cada uno de los tipos de recomendación antes de efectuar una compra.




Fuente: Elaboración propia (2024)

En concreto, la sexta pregunta trataba sobre la frecuencia con la que los clientes consideraban cada tipo de recomendaciones antes de efectuar una compra. La **Figura 12** muestra cómo más del 75% de los encuestados indica que **las reseñas de otros usuarios y valoraciones de los productos constituyen las recomendaciones a las que “frecuentemente” o “siempre” prestan atención**. Además, cerca del 50% dice que a veces o frecuentemente también considera las recomendaciones similares a las que ha visto últimamente, compras anteriores o los productos más vendidos. Por el contrario, las ofertas personalizadas, así como las sugerencias de la página

de inicio suelen considerarse tan sólo a veces o raramente, de lo que se podría deducir que se perciben como menos ajustadas o confiables.

Figura 13: Percepción que los consumidores de Amazon encuestados tienen de la relevancia de cada uno de los distintos tipos de recomendación.



Fuente: Elaboración propia (2024)

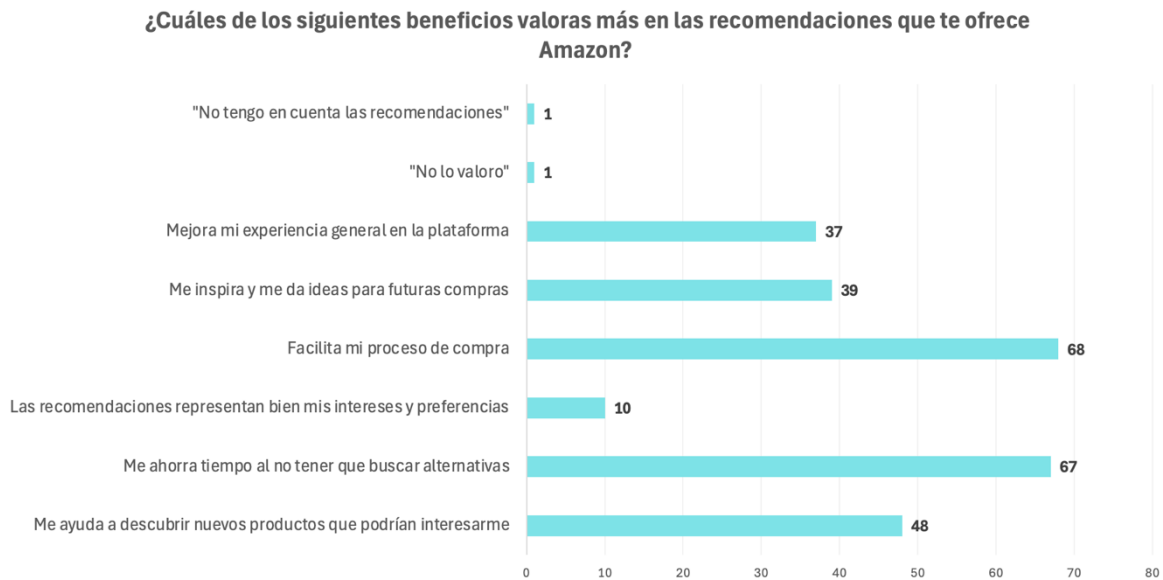
En cuanto a la percepción de la relevancia que cobra cada tipo de recomendación, se repite la tendencia de la pregunta anterior, siendo **las reseñas (87%) y valoraciones (85%) las más significativas**, con una relevancia promedio de 4,37 y un 4,30 sobre 5 respectivamente, clasificándolas como “bastante o muy relevantes”. A éstas les siguen las recomendaciones similares a las búsquedas y compras anteriores, después las ofertas y los más vendidos, tal y como se puede observar en la *Figura 13*. Igualmente, son las sugerencias de la página de inicio las que están peor valoradas frente al resto.

A continuación, se abordó la percepción que los consumidores tienen de las recomendaciones en tanto que reflejen sus intereses y preferencias. En este caso, y como era de esperar, **las recomendaciones basadas en el historial de compras y navegación de la plataforma son aquellas que parecen alinearse mejor con sus gustos a nivel personal**.

De acuerdo con la pregunta 9, los beneficios que proporcionan las recomendaciones y que los clientes de Amazon más valoran son: “la facilidad en el proceso de compra” (65%) y “el ahorro de tiempo al no tener que buscar alternativas” (64%). Así pues, estos beneficios subrayan que **las recomendaciones sirven para aliviar la fatiga cognitiva y agilizar la toma de decisiones de compra**. Si bien, aunque algo menos valorados, los consumidores también resaltan el hecho de que les ayuda a descubrir nuevos productos (46%) y les inspira para futuras compras (37%). Por

otro lado, y según la *Figura 14*, sólo el 10% de los consumidores afirma que uno de los beneficios sea que se ajusten a sus intereses particulares.

Figura 14: Beneficios que destacan los consumidores encuestados de las recomendaciones que les ofrece Amazon.



Fuente: Elaboración propia (2024)

A pesar de ello, cuando se les preguntó sobre su **experiencia de compra**, el 67% de los usuarios admitió que las recomendaciones personalizadas mejoran “bastante” o “mucho” su interacción con la plataforma, repercutiendo en su satisfacción general, con una puntuación promedio de 3,74 sobre 5. La **indiferencia respecto al orden y la presentación de las sugerencias** es la expresión más popular (35%). Mientras que el 35% considera que la disposición es “inadecuada” o “muy inadecuada”, sólo el 3% la califica de “muy adecuada”. Sin embargo, **el 41% de los individuos afirma que la experiencia de navegación en la plataforma es “bastante o muy satisfactoria e intuitiva”**, frente al 45% al que le es indiferente.

Cabe mencionar aquí que, gran parte de las personas que se muestran conformes con la presentación de las recomendaciones y la experiencia de navegación, pertenecen a los grupos de edad más altos. En cambio, **son los más jóvenes los que tienden a evaluar la disposición y la navegación a la baja**, lo que demuestra que le dan más importancia a la forma en que se presentan las sugerencias, ya que probablemente tengan expectativas más altas en sus interacciones con Amazon derivadas del uso extendido que le dan a las nuevas tecnologías.

Los resultados de la encuesta reflejan cierto interés en contemplar nuevas iniciativas que ayuden a afinar las recomendaciones y a mejorar la experiencia en la plataforma. Por un lado, **el 65% estarían interesados en que Amazon desarrollara tableros colaborativos** donde compartir

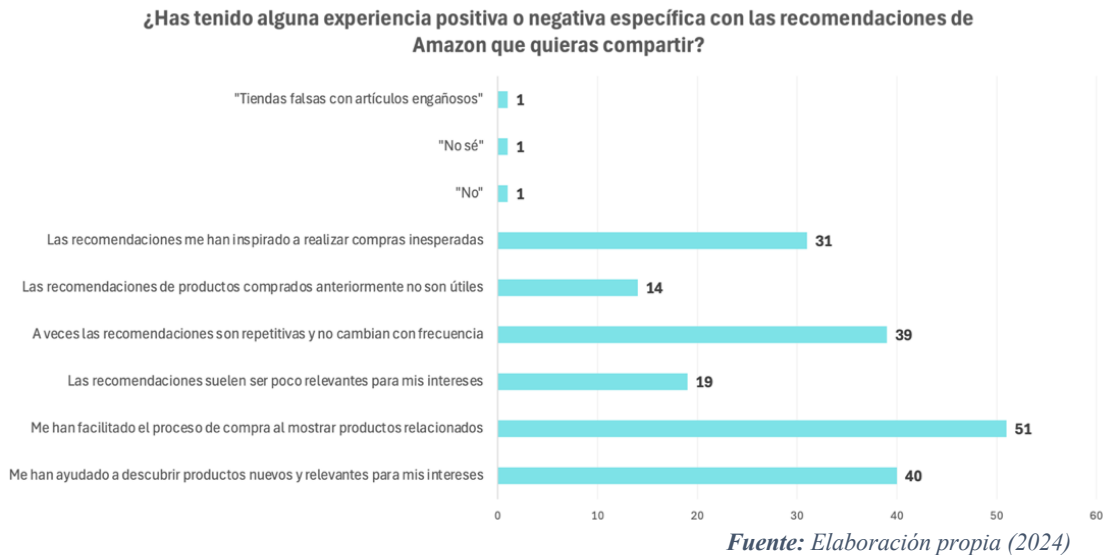
ideas con amigos y familiares. Esta iniciativa se ve respaldada por el hecho de que el **64% de los consumidores estaría dispuesto a interactuar con dichos tableros**, frente al 14% que no cree que lo haría. Además, **el 90% expresó que le gustaría poder contar con una sección donde Amazon les permitiera personalizar sus preferencias** de manera individual, de tal forma que las recomendaciones se ajusten mejor a sus perfiles. Tanto es así que, de nuevo, **el 90% estaría interesado en que la plataforma incluyera opciones de personalización avanzadas**, como filtros que permitan excluir ciertas categorías, marcas o productos.

No obstante, recomendaciones generadas a partir del contenido consultado o publicado en las redes sociales suscitan más dudas. En este caso, **sólo el 23% estaría dispuesto a consentir que Amazon les facilitara sugerencias en base a los datos de sus redes**, frente al 48% que directamente descarta esta propuesta. Esto sugiere que la **privacidad** sigue siendo uno de los elementos clave para el consumidor a la hora de manejar su información personal. Por tanto, a pesar de que todas las iniciativas están orientadas a mejorar la satisfacción del usuario, éstas deben diseñarse sin dejar de lado sus derechos fundamentales.

Por último, se preguntó a los consumidores sobre las características que añadirían y los cambios que introducirían para mejorar la precisión, la calidad y la presentación de las recomendaciones. En cuanto a las **características que incluirían, destacan las opciones avanzadas para personalizar sus preferencias (61%), seguido por la implementación de tableros colaborativos (60%)** y de los filtros para eliminar determinados productos (50%). No parece que proporcionar recomendaciones basadas en compras anteriores ni mejores opciones para explorar nuevas categorías sean la prioridad. En la misma línea de antes, las recomendaciones basadas en el contenido de las redes sociales no tienen gran aceptación (24%), lo que refuerza el planteamiento.

Sobre los **cambios en la presentación, el 66% consideran que el principal sería introducir filtros avanzados** de precio, categoría... además de **reorganizar las recomendaciones** para mostrarles primero aquellas de sus categorías favoritas (57%). Aunque es secundario, el 36% de los consumidores opina que no estaría de más modificar el diseño de la plataforma para hacerlo más atractivo. Por su parte, el **49% recalca la facilidad en el proceso de compra como experiencia positiva** y el 38% la inspiración para descubrir nuevos productos interesantes. Si bien, el 37% se queja de que las recomendaciones suelen ser repetitivas y un 18% menciona que no se ajustan del todo a sus preferencias, tal y como se observa en la *Figura 15*.

Figura 15: Experiencias que destacan los consumidores de Amazon encuestados respecto a las recomendaciones.



En conclusión, los resultados indican que los usuarios valoran especialmente aquellas recomendaciones que les ayudan a **agilizar el proceso de compra**, y más hoy en día donde el tiempo es un bien preciado. Las sugerencias de nuevos productos que podrían resultar interesantes y que podrían llegar a inspirar futuras compras, se perciben como secundarias, priorizando la eficiencia en las primeras fases del *customer journey*. A su vez, la confianza que depositan los consumidores en las reseñas y valoraciones de otros usuarios es lo que verdaderamente les transmite fiabilidad que extrapolan a Amazon como empresa y que les empuja a efectuar o no la compra.

4.5. Oportunidades y Áreas de Mejora

A raíz del análisis de los resultados del cuestionario, se identificaron una serie de mejoras y oportunidades que podría implementar Amazon para mejorar la experiencia de los usuarios con las recomendaciones, y en general con la plataforma. Entre ellas, es preciso mencionar las siguientes de acuerdo con la *Figura 16*:

Figura 16: Oportunidades e iniciativas de mejora de las recomendaciones actuales de Amazon.



- 1) Tableros colaborativos con amigos y familiares:** la gran mayoría de los encuestados mostró interés en utilizar tableros colaborativos donde poder compartir ideas y listas de productos con su círculo más cercano. Esta iniciativa, similar a lo que ya propone Pinterest, sería de valor añadido a la hora de tomar decisiones consensuadas sobre un proyecto común entre varios usuarios, como puede ser: amueblar una nueva casa, un regalo en conjunto, u organizar un evento, entre otros. Los datos apuntan a que esta iniciativa sería bienvenida, con más del 60% de los encuestados dispuestos a interactuar con dichos tableros. Además, esta oportunidad animaría a los usuarios a participar activamente en la plataforma, ayudando a mejorar la calidad de las recomendaciones que se generan a partir de los productos guardados en el tablero y prueba que los usuarios valorarían positivamente contar una dimensión más social.
- 2) Sección para personalizar las preferencias de las recomendaciones:** las respuestas registradas sugieren que los consumidores están altamente interesados en mejorar la calidad de las recomendaciones, de manera que representen fielmente sus gustos con tal de facilitarles aún más si cabe el proceso de compra. Esta funcionalidad permitirá que cada usuario ajuste a mano sus preferencias con cada interacción si fuese necesario. Como los intereses pueden ser puntuales y cambiantes, las recomendaciones deberían ser capaces de adaptarse al mismo ritmo que éstos cambian. Esta sección podría ayudar a crear una mejor experiencia para el 18% de los encuestados que admitieron no sentirse identificados con las recomendaciones que en general se les presentan. Lo mismo ocurre con ciertos tipos de recomendaciones como las “ofertas para ti” o las de la página de inicio, que parecen no lograr conectar del todo con el público objetivo.

- 3) Filtros avanzados para refinar las recomendaciones generadas:** en la misma línea, el 90% de los consumidores indicó que sería interesante incluir filtros adicionales en los que se pudieran excluir ciertos tipos de productos o categorías que no son relevantes en un momento dado. Estas herramientas dotarían al usuario de un mayor control sobre lo que se les muestra, maximizando la eficiencia con la que se generan las recomendaciones, agilizando la compra y mejorando la experiencia en Amazon.
- 4) Mejora de las sugerencias de la página de inicio:** de los resultados del cuestionario se deriva una necesidad latente de replantear las sugerencias de la página de inicio, ya que cerca del 60% dice no considerarlas en sus decisiones de compra. No sólo eso, sino que tampoco les parecen relevantes ni sienten que reflejen sus intereses. Las puntuaciones promedio sobre las percepciones de relevancia (2,20) y afinidad (2,33) son las más bajas de entre todos los tipos de recomendaciones, lo cual es preocupante cuando éstas son el primer punto de contacto visual con la plataforma. Por ello, deberían rediseñarse ajustándolas en la sección de preferencias para captar la atención de los consumidores y fomentar su interacción con la plataforma.
- 5) Aumento de la frecuencia con la que se generan las recomendaciones:** la repetitividad de las recomendaciones fue uno de los elementos negativos a destacar por 39 individuos (37%). El verdadero problema está en que, cuando las recomendaciones son repetitivas, el consumidor pierde interés y deja de interactuar con el sistema, que no es capaz de aprender a generar sugerencias nuevas precisamente porque no tiene suficientes datos actualizados sobre los intereses del usuario. Esto contribuye a la creación de un ciclo vicioso, que podría prevenirse en primer lugar mejorando las recomendaciones de la página de inicio. Aumentar la frecuencia de las recomendaciones ayudaría al 39% de los encuestados que valoraría contar con mejores opciones para explorar productos nuevos o de categorías menos conocidas.
- 6) Cambios en la disposición y presentación de las recomendaciones:** la forma en que se ordenan y presentan las recomendaciones fue otra de las áreas a mejorar de Amazon, especialmente para los grupos de edad más jóvenes. Dado que el 30% considera la disposición como “adecuada” o “muy adecuada”, una solución podría pasar por llevar a cabo pruebas A/B y evaluar la interacción de los usuarios en dos formatos de plataforma: una dirigida a los jóvenes con una interfaz más moderna y visual y otra manteniendo la disposición actual para las generaciones más adultas que ya se han acostumbrado a ella y a las que cambios en la interfaz les pueden resultar un reto. Estas pruebas se realizarían de

forma temporal y permitirían verificar si el diseño cumple con las expectativas de cada grupo.

- 7) **Recomendaciones basadas en redes sociales:** a pesar de la división de opiniones de esta iniciativa, podría resultar interesante desarrollar una herramienta que permita vincular la cuenta del usuario en Amazon con sus cuentas en redes sociales. Esta funcionalidad sería opcional y estaría exclusivamente disponible para aquellos consumidores que diesen su consentimiento, garantizando la transparencia en el manejo de la información por parte de Amazon. De este modo, la empresa podría ofrecer una experiencia de compra aún más digitalizada para los consumidores que así lo prefieran.

CAPÍTULO V: Conclusiones y Desarrollos Futuros

El Capítulo V pone fin al presente trabajo, en el que se verifica que se cumple con los objetivos fijados originalmente y de los que se derivan una serie de conclusiones. Asimismo, se plantean las limitaciones del estudio y se presentan las líneas de desarrollo futuro que podrían ser de valor añadido.

5.1. Conclusiones

Antes de presentar las conclusiones, es preciso señalar que este trabajo ha permitido explorar en profundidad cómo los sistemas de recomendación influyen en el comportamiento de los consumidores de los *marketplaces* B2C, tomando a Amazon como caso de estudio. Mediante un estudio mixto, que combina la revisión de bibliografía académica y un análisis exploratorio, se han identificado tanto las ventajas, como las mejoras que podrían integrar los sistemas de recomendación para optimizar la experiencia de compra, ofreciendo una visión estratégica de la personalización en los *marketplaces*. Así pues, las conclusiones principales del trabajo se enumeran a continuación:

- 1) **La importancia estratégica de los sistemas de recomendación en los *marketplaces* B2C:** el trabajo ha demostrado cómo los sistemas de recomendación se consolidan como la herramienta clave no sólo para personalizar la experiencia de los clientes de las plataformas *online*, sino para agilizar el *customer journey*. En plataformas como Amazon, estos sistemas desempeñan un papel esencial. Por un lado, ayudando a los usuarios a encontrar lo que buscan en un medio saturado de información y simplificando su toma de decisiones, y por otro, mejorando la visibilidad de los productos de los fabricantes en un entorno altamente competitivo, favoreciendo a su vez las ventas adicionales mediante *up-selling* y *cross-selling*.
- 2) **El notable impacto del sistema de recomendación de Amazon en los consumidores:** el análisis empírico ha verificado que las reseñas y valoraciones de otros clientes son las recomendaciones más influyentes, posicionándolas por encima de otro tipo de sugerencias por su gran utilidad y relevancia percibida. Con este hallazgo queda comprobado que las experiencias de compras de anteriores clientes, impactan directamente en las decisiones de compra de futuros clientes, ya que generan confianza.

En cambio, las recomendaciones de la página de inicio se perciben como más genéricas o impersonales, lo que reduce el *engagement* y su eficacia.

- 3) **El contraste entre beneficios y limitaciones de las estrategias de personalización de Amazon:** la personalización que, en el caso de Amazon, se lleva a cabo por medio del filtrado colaborativo basado en artículos, se basa en el historial de compra y en las preferencias individuales, es efectiva como para fidelizar al cliente en términos generales. Sin embargo, los comentarios de ciertos encuestados en relación a la insuficiente frecuencia con la que se actualizan las recomendaciones, condiciona la percepción de utilidad y relevancia que tienen de ellas. Esta limitación se podría justificar directamente del comportamiento del usuario que, desincentivado deja de interactuar con la plataforma, y por tanto con el sistema de recomendación, frenando el aprendizaje continuo de los algoritmos, impactando negativamente en su rendimiento y promoviendo que no se generen recomendaciones novedosas.
- 4) **Las oportunidades y áreas de mejora identificadas en el caso Amazon:** el análisis exploratorio desarrollado en el trabajo ha permitido identificar varias iniciativas que podrían implementarse para mejorar no sólo la experiencia del usuario, sino el desempeño del sistema de recomendación. Las más significativas son:
- **Sugerencias más dinámicas y personalizadas:** independientemente de la medida en que el usuario interactúe con la plataforma, Amazon debería tratar de supervisar que las recomendaciones se actualicen con mayor frecuencia para poder ofrecer productos que se adapten a las cambiantes expectativas de los usuarios. Si es usuario no interactúa regularmente con el sistema, este ajuste se puede llevar a cabo por elicitación explícita, preguntándole directamente cuáles son sus intereses en ese momento.
 - **Optimización de la página de inicio:** la página de inicio es el primer punto de contacto cuando se accede a Amazon y debe mostrar las recomendaciones más relevantes y atractivas para el usuario, captando su interés desde el principio y manteniéndole en la plataforma, mientras le ayuda a navegar de una recomendación a otra dentro de la misma.
 - **Integración de filtros avanzados:** incluir opciones que permitan a los usuarios personalizar las recomendaciones que se les presentan, excluyendo categorías o fijando precios, mejoraría no sólo su percepción de la utilidad del sistema, sino que maximizaría la calidad de las recomendaciones.

- **Implementación de funcionalidades adicionales:** incorporar tableros colaborativos donde compartir ideas, potenciaría la conexión social en la plataforma, fortalecería el vínculo con los sistemas de recomendación, e incentivaría el descubrimiento de nuevos productos.
- 5) **La relación entre los hallazgos empíricos y las observaciones teóricas:** los resultados de la encuesta coinciden con lo mencionado en la revisión académica del Capítulo III sobre el impacto de los sistemas de recomendación en los consumidores. En concreto, las opiniones de los participantes resaltan la importancia de la personalización en su experiencia de compra y la reducción del esfuerzo cognitivo como beneficio principal. Si bien, los resultados también muestran que hay aspectos en los que las estrategias actuales no cumplen con las expectativas de los usuarios, como la disposición y organización de las recomendaciones, entre otros.
 - 6) **Las oportunidades de crecimiento para Amazon:** la gestión estratégica de los sistemas de recomendación se alza como un elemento clave a la hora de atraer y retener clientes a largo plazo. Mejorar las áreas indicadas en el presente trabajo no sólo optimizaría la experiencia de compra y la satisfacción del consumidor, sino que también reforzaría la posición de Amazon como la empresa líder en comercio electrónico, brindando beneficios a consumidores y optimizando el posicionamiento de los fabricantes. Implementar las iniciativas aquí mencionadas, orientaría a la empresa en la consecución de su misión de convertirse en “la más centrada en el consumidor del mundo”.
 - 7) **El impacto determinante de los sistemas de recomendación en el comercio electrónico:** con el caso de Amazon, se ha comprobado que los sistemas de recomendación son herramientas clave en el desarrollo de estrategias de marketing y comercio electrónico, dado que pueden influir en las decisiones de compra, generar confianza y fortalecer la lealtad del cliente en un entorno digital cada día más competitivo.

5.2. Limitaciones y Desarrollos Futuros

Como todo trabajo de investigación, éste cuenta con ciertas limitaciones que ofrecen oportunidades para continuar y ampliar el análisis realizado hasta el momento.

En primer lugar, el estudio se ha enfocado **únicamente en los sistemas de recomendación**, dejando fuera otras estrategias de personalización disponibles en los *marketplaces*, como son las **ofertas flash, los precios dinámicos o los bundles** de productos relacionados. Estas herramientas también repercuten en el comportamiento del consumidor y su integración con los sistemas de recomendación tradicionales podrían ofrecer una visión más global del impacto conjunto en la experiencia de compra para futuras investigaciones.

Aunque el trabajo **se ha centrado en Amazon como caso de estudio, cada marketplace cuenta con características únicas** que influyen en la efectividad de los sistemas de recomendación. Por ello, sería interesante que la segunda línea de investigación extendiera el análisis a otros *marketplaces*, para poder extraer conclusiones de carácter más general y ver cómo las particularidades de cada plataforma y sistema de recomendación influyen en las percepciones y comportamientos de los consumidores.

En cuanto a la metodología, la **técnica de encuesta mediante cuestionario online y autoadministrado** dota a los participantes de cierta libertad de expresión y flexibilidad a la hora de completarlo, pero está sujeta a las restricciones del muestreo no probabilístico. Aunque esta técnica es válida para realizar estudios exploratorios como en este caso, el uso de muestreos probabilísticos o entrevistas en profundidad podría ampliar la diversidad de los perfiles encuestados, a la vez que ayudarían a obtener *insights* cualitativos. Además, sería interesante incorporar un **análisis multivariable** como el *clustering* para segmentar los consumidores por grupos según su opinión o un **análisis factorial** para poder determinar los factores ocultos y que justifican la relevancia o utilidad de las recomendaciones.

Por su parte, el análisis está enfocado en examinar las **percepciones y preferencias actuales de los consumidores**. Como tanto los intereses, como la evolución de los sistemas de recomendación son variables dinámicas, sería recomendable llevar a cabo un **estudio longitudinal** que permitiera determinar cómo han cambiado las actitudes de los consumidores en tanto que pasa el tiempo y se desarrollan sistemas más avanzados que incluyen todas las funcionalidades e iniciativas propuestas en este trabajo.

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Irene María Castaño Martínez, estudiante del Grado en Administración y Dirección de Empresas de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "El Impacto de los Sistemas de Recomendación en los Consumidores: el Caso de Amazon", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
3. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
4. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
5. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
6. **Generador de encuestas:** Para diseñar cuestionarios preliminares.
7. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 30/11/2024

Firma:



CAPÍTULO VI: Bibliografía

Aaker, D. (1991). *Managing Brand equity: Capitalizing on the Value of a Brand name*. New York: The Free Press. <https://doi.org/10.1016/0148-2963%2894%2990009-4>

Adisman. (2023, Enero 20). ¿En qué países vende Amazon? *Adisman*. <https://adisman.com/paises-en-los-que-amazon-vende/>

Alpaydin, E. (2021). *Machine Learning*. MIT Press.

Amazon (s.f.). Quiénes somos. *Amazon*. <https://www.aboutamazon.es/quienes-somos>

Amazon Web Services. (s.f.). ¿Qué es el aprendizaje automático? <https://aws.amazon.com/es/what-is/machine-learning/>

Amazon. (1997). 1997 Letter to Shareholders. *Amazon*. Recuperado de: https://s2.q4cdn.com/299287126/files/doc_financials/annual/Shareholderletter97.pdf

Amazon. (2023). 2023 Annual Report. *Amazon*. Recuperado de: https://s2.q4cdn.com/299287126/files/doc_financials/2024/ar/Amazon-com-Inc-2023-Annual-Report.pdf

Amazon. (2024). Logística de Amazon: Tarifas Europeas. *Amazon*. <https://m.media-amazon.com/images/G/02/sell/images/240919-FBA-Rate-Card-1001-UK-spa-ES.pdf>

Amazon. (s.f.). Ayuda y servicio de Atención al cliente: Amazon Renewed. *Amazon*. <https://www.amazon.es/gp/help/customer/display.html?nodeId=GRAS7M4E8YJCLWH7#:~:text=Amazon%20Renewed%20es%20tu%20punto,y%20con%20la%20caja%20abierta>

Amazon. (s.f.). Ayuda y servicio de Atención al cliente: cuota de suscripción a Amazon Prime. *Amazon*. <https://www.amazon.es/gp/help/customer/display.html?nodeId=G34EUPKVMYFW8N2U>

Amazon. (s.f.). Descubre Cuánto Cuesta Vender en Amazon. *Amazon*. <https://sell.amazon.es/precios>

Amazon. (s.f.). Llega a millones de clientes con Amazon Handmade. *Amazon*. <https://sell.amazon.es/programas/handmade>

Amazon. (s.f.). Logística de Amazon: Gestionamos la logística por ti. *Amazon*.
<https://sell.amazon.es/logistica-de-amazon>

APD. (2024). *Algoritmos del Machine Learning*. <https://www.apd.es/algoritmos-del-machine-learning/>

Arsenault, M. (2021, Julio 19). The Amazon Recommendations Secret to Selling More Online. *Rejoiner*. <https://www.rejoiner.com/resources/amazon-recommendations-secret-selling-online>

AWS. (s.f.). AWS Data Exchange: Precios de AWS Data Exchange. *Amazon Web Services*. <https://aws.amazon.com/es/data-exchange/pricing/>

Babatunde, S. O., Odejide, O. A., Edunjobi, T. E., & Ogundipe, D. O. (2024). The role of AI in marketing personalization: A theoretical exploration of consumer engagement strategies. *International Journal of Management & Entrepreneurship Research*, 6(3), 936–949. <https://doi.org/10.51594/ijmer.v6i3.964>

BBVA. (s.f.). ‘Machine learning’: ¿Qué es y cómo funciona el maestro en reconocer patrones? <https://www.bbva.com/es/innovacion/machine-learning-que-es-y-como-funciona/>

Bello, E. (2021, Noviembre 23). Qué es un marketplace, qué tipos existen y cómo funcionan. *IEBSchool*. <https://www.iebschool.com/blog/metricas-marketplace-mas-utilizadas-e-commerce/>

Bergmann, D. & Stryker, C. (2023, Noviembre 23). ¿Qué es un autocodificador? *IBM*. <https://www.ibm.com/es-es/topics/autoencoder>

Biernacki, P., & Waldorf, D. (1981). Snowball sampling: Problems and Techniques of Chain Referral Sampling. *Sociological Methods & Research*, 10(2), 141–163. <https://doi.org/10.1177/004912418101000205>

Bobadilla, J., Alonso, S., & Hernando, A. (2020). Deep learning architecture for collaborative filtering recommender systems. *Applied Sciences*, 10(7), 2441. <https://doi.org/10.3390/app10072441>

Boo, S.; Busser, J.; Baloghu, S. (2008). A model of customer-based brand equity and its application to multiple Destinations. *Tourism Management*, 30 (1), 219–231. <http://dx.doi.org/10.1016/j.tourman.2008.06.003>

Bouguezzi, S. (2024, Marzo 18). How does the Amazon Recommendation System work? *Baeldung*. <https://www.baeldung.com/es/amazon-recommendation-system>

Bozkurt Ates, D., & Odzic, S. (2023). *The impact of personalization on consumer purchase intention in online shopping*. School of Business, Society & Engineering, Mälardalen University.

Recuperado de: <https://www.diva-portal.org/smash/get/diva2:1760914/FULLTEXT01.pdf>

Bradlow, E. T., Gangwar, M., Kopalle, P., & Voleti, S. (2017). The role of big data and predictive analytics in retailing. *Journal of Retailing*, 93(1), 79-95.

<https://doi.org/10.1016/j.jretai.2016.12.004>

Bryman, A. (2016). *Social research methods*. Oxford University Press. Recuperado de:

<https://ktpu.kpi.ua/wp-content/uploads/2014/02/social-research-methods-alan-bryman.pdf>

Burtch, G., Ghose, A., & Wattal, S. (2014). An Empirical Examination of the Antecedents and Consequences of Contribution Patterns in Crowd-Funded Markets. *Information Systems Research*, 24(3), 499-519. <https://doi.org/10.1287/isre.1120.0468>

ChoiceStream. (2008). *Personalization survey: Consumer trends and perceptions*. ChoiceStream, Inc. <https://www.choicestream.com>

Corrot, P., & Nussenbaum, A. (2023). The Online Marketplace Advantage: Sell More, Scale Faster, and Create a World-Class Digital Customer Experience.

Wiley. <https://www.oreilly.com/library/view/the-online-marketplace/9781119864745/>

Davenport, T. H., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24-42.

<https://doi.org/10.1007/s11747-019-00696-0>

Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87. <https://doi.org/10.1145/2347736.2347755>

EAE Business School Barcelona. (s.f.). Fill rate: ¿Qué es y por qué es importante en logística? *EAE Business School Barcelona*. <https://www.eaebarcelona.com/es/blog/que-es-el-fill-rate#:~:text=EI%20fill%20rate%20es%20un%20indicador%20empleado%20en%20el%20el,un%20servicio%20de%20env%C3%ADos%2Ftransportes>

eDesk. (2024, Agosto 21). Estadísticas del mercado de Amazon 2024. *eDesk*. <https://www.edesk.com/es/blog/estadisticas-amazon/>

EDICOM. (2020, Agosto 31). ¿Qué es el e-Procurement? Beneficios y obligaciones. *EDICOM*. <https://edicomgroup.es/blog/que-es-el-e-procurement-beneficios-y-obligaciones>

Einav, L., Farronato, C., & Levin, J. (2016). Peer-to-Peer Markets. *Annual Review of Economics*, 8, 615-635. <https://doi.org/10.1146/annurev-economics-080315-015334>

Etikan, I., Musa, S. A., & Alkassim, R. S. (2016). Comparison of convenience sampling and purposive sampling. *American Journal of Theoretical and Applied Statistics*, 5(1), 1-4. <https://doi.org/10.11648/j.ajtas.20160501.11>

Francés Monedero, T. (2020). *Impacto del machine learning en el sistema financiero*. Universidad Pontificia de Comillas. Recuperado de: <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/42692/Impacto%20del%20machine%20learning%20en%20el%20sistema%20financiero%20-%20Francés%20Monedero%20c%20Teresa.pdf?sequence=1&isAllowed=y>

Gallart Camahort, V. (2017). *Influencia de la experiencia de compra en el valor de marca del comercio detallista: Una aplicación al comercio de la Comunidad Valenciana*. Universitat Jaume I. Recuperado de: <https://www.tdx.cat/handle/10803/404734#page=1>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Gorgoglione, M., Panniello, U., & Tuzhilin, A. (2019). Recommendation strategies in personalization applications. *Information & Management*, 56(3), 1031-1043. <https://doi.org/10.1016/j.im.2019.01.005>

Grewal, D., Roggeveen, A. L., & Nordfält, J. (2017). The future of retailing. *Journal of Retailing*, 93(1), 1-6. <https://doi.org/10.1016/j.jretai.2016.12.008>

Hagen, L., Uetake, K., Yang, N., Bollinger, B., Chaney, A. J. B., Dzyabura, D., Etkin, J., Goldfarb, A., Liu, L., Sudhir, K., Wang, Y., & Wright, J. R. (2020). How can machine learning aid behavioral marketing research? *Marketing Letters*, 31(4), 361-370. <https://doi.org/10.1007/s11002-020-09535-7>

Hagiu, A., & Wright, J. (2015). Marketplace or Reseller? *Management Science*, 61(1), 184-203. <https://doi.org/10.1287/mnsc.2014.2042>

Hardesty, L. (2019, Noviembre 22). The history of Amazon's recommendation algorithm: Collaborative filtering and beyond. *Amazon Science*. <https://www.amazon.science/the-history-of-amazons-recommendation-algorithm>

Hawkins, J., & Blakeslee, S. (2004). *On intelligence*. Henry Holt and Co.

He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017). Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web*, 173-182. <https://doi.org/10.1145/3038912.3052569>

Herhausen, D., Bernritter, S. F., Ngai, E. W. T., Kumar, A., & Delen, D. (2024). *Machine learning in marketing: Recent progress and future research directions*. *Journal of Business Research*, 170, 114254. <https://doi.org/10.1016/j.jbusres.2023.114254>

Huang, M.-H., & Rust, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), 155–172. <https://doi.org/10.1177/1094670517752459>

Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30-50. <https://doi.org/10.1007/s11747-020-00749-9>

Iberdrola. (s.f.). *Qué es el 'machine learning': Descubre los principales beneficios del Machine Learning*. <https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>

IBM. (s.f.). *¿Qué es el machine learning (ML)?* <https://www.ibm.com/es-es/topics/machine-learning>

IBM. (s.f.). *¿Qué es un algoritmo de machine learning?* <https://www.ibm.com/es-es/topics/machine-learning-algorithms>

Imaeka, C., & Uford, I. (2023). Comparative analysis and evaluation of business and financial performance of Amazon.com. *European Journal of Business, Economics and Accountancy*, 11(2), 69-72. https://www.idpublications.org/wp-content/uploads/2023/07/Full-Paper-COMPARATIVE-ANALYSIS-AND-EVALUATION-OF-BUSINESS-AND-FINANCIAL-PERFORMANCE-OF-AMAZON.com_.pdf

Jannach, D., & Adomavicius, G. (2016). *Recommendations with purpose*. In *Proceedings of the 10th ACM Conference on Recommender Systems* (pp. 3-10). ACM. <https://doi.org/10.1145/2959100.2959186>

Javed, S. (2022, Abril 8). A guide to the commission marketplace revenue model. *CedCommerce*. <https://cedcommerce.com/blog/the-commission-based-marketplace-revenue-model/>

Keller, K. L. (1993). Conceptualizing, measuring, and managing consumer-based brand equity. *Journal of Marketing*, 57(1), 1–22. <https://doi.org/10.1177/002224299906300105>

Kenney, M., & Zysman, J. (2016). The Rise of the Platform Economy. *Issues in Science and Technology*, 32(3), 61-69. <http://www.jstor.org/stable/24727063>

Khusro, S., Ali, Z., & Ullah, I. (2016). Recommender systems: Issues, challenges, and research opportunities. In K. J. Kim & N. Joukov (Eds.), *Information Science and Applications (ICISA) 2016*, Lecture Notes in Electrical Engineering (Vol. 376, pp. 1179–1189). Springer. https://doi.org/10.1007/978-981-10-0557-2_112

Kim, D. J., Ferrin, D. L., & Rao, H. R. (2008). A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents. *Decision Support Systems*, 44(2), 544-564. <https://doi.org/10.1016/j.dss.2007.07.001>

Kumar, A. (2008). From mass customization to strategic personalization: A strategic transformation. *International Journal of Flexible Manufacturing Systems*, 19(4), 533-547. <https://doi.org/10.1007/s10696-008-9048-6>

Kumar, V. (2018). Transformative Marketing: The Next 20 Years. *Journal of Marketing*, 82(4), 1-12. <https://doi.org/10.1177/0022242918791379>

Lacort, J. (2022, Febrero 4). Amazon factura tanto por publicidad que supera los ingresos de YouTube o Netflix. *Xataka*. <https://www.xataka.com/empresas-y-economia/amazon-detalla-primera-vez-facturacion-su-negocio-publicitario-superior-al-microsoft-youtube>

Li, H., Fang, Y., Wang, Y., Lim, K. H., & Liang, L. (2015). Are all signals equal? Investigating the differential effects of online signals on the sales performance of e-marketplace sellers. *Information Technology & People*, 28(3), 699-723. <https://doi.org/10.1108/ITP-11-2014-0265>

Li, H., Fang, Y., Wang, Y., Lim, K. H., & Liang, L. (2015). Are all signals equal? Investigating the differential effects of online signals on the sales performance of e-marketplace sellers. *Information Technology & People*, 28(3), 699-723. <https://doi.org/10.1108/ITP-11-2014-0265>

Lindecrantz, E., Tjon Pian Gi, M., & Zerbi, S. (2020). Personalizing the customer experience: Driving differentiation in retail. *McKinsey & Company*. Recuperado de: <https://www.mckinsey.com/industries/retail/our-insights/personalizing-the-customer-experience-driving-differentiation-in-retail>

Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76-80. <https://doi.org/10.1109/MIC.2003.1167344>

Litslink. (2024, Julio 25). Airbnb, Uber, and Others - Success of Marketplace Startups and their Business Models. *Litslink*. <https://litslink.com/blog/airbnb-uber-and-others-whats-behind-the-success-of-marketplace-startups-and-their-business-models>

Lops, P., de Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor (Eds.), *Recommender systems handbook* (pp. 73-105). Springer. https://doi.org/10.1007/978-0-387-85820-3_3

Ma, L., & Sun, B. (2020). Machine learning and AI in marketing: Connecting computing power to human insights. *International Journal of Research in Marketing*, 37(3), 481-504. <https://doi.org/10.1016/j.ijresmar.2020.04.005>

MacKenzie, I., Meyer, C., & Noble, S. (2013). How retailers can keep up with consumers. *McKinsey & Company*. Recuperado de: <https://www.mckinsey.com/industries/retail/our-insights/how-retailers-can-keep-up-with-consumers>

Mahesh, B. (2019). *Machine learning algorithms - A review*. *International Journal of Science and Research (IJSR)*, 9(1), 381-386. <https://doi.org/10.21275/ART20203995>

Maier, E., & Wieringa, J. (2021). Acquiring customers through online marketplaces? The effect of marketplace sales on sales in a retailer's own channels. *International Journal of Research in Marketing*, 38(2), 311-328. <https://doi.org/10.1016/j.ijresmar.2020.09.007>

Mellahi, K. & Johnson, M. (2000). Does it pay to be a first mover in e.commerce? The case of Amazon.com. *Management Decision*, 38(7), 445-452. <http://dx.doi.org/10.1108/00251740010373458>

Mena Roa, M. (2021, Julio, 15). La popularidad de Amazon antes y después de la pandemia. *Statista*. Recuperado de: <https://es.statista.com/grafico/25330/encuestados-que-han-comprado-en-amazon-en-los-ultimos-doce-meses/>

Ngai, E. W. T., & Wu, Y. (2022). Machine learning in marketing: A literature review, conceptual framework, and research agenda. *Journal of Business Research*, 145, 35-48. <https://doi.org/10.1016/j.jbusres.2022.02.049>

Padeco Global. (2023, Septiembre 28). Estás pensando en vender tus productos en un marketplace internacional [Post de LinkedIn]. *LinkedIn*. https://www.linkedin.com/posts/padeco-global_estás-pensando-en-vender-tus-productos-en-activity-7183389496338440192-bz-z/?originalSubdomain=es

Parker, S. (2022, Marzo 11). Personalization Strategies Used by Amazon to Upsell and Cross-Sell Products. *Oppizi*. <https://www.oppizi.com/blog/sales/personalization-strategies-used-by-amazon-to-upsell-and-cross-sell-products/>

Parra, E. (2024, Abril 25). Los marketplaces dominan el comercio electrónico global: Actualizado abril 2024. *Innova Digital Export*. <https://www.innovaexport.com/dominio-marketplaces-ecommerce-abril-2024/>

Pine, B. J. (1993). *Mass customization: The new frontier in business competition*. Harvard Business School Press.

Pu, P., Chen, L., & Hu, R. (2012). Evaluating recommender systems from the user's perspective: Survey of the state of the art. *User Modeling and User-Adapted Interaction*, 22(4-5), 317–355. <https://doi.org/10.1007/s11257-011-9115-7>

Raghuwanshi, S. K., & Pateriya, R. K. (2019). Collaborative filtering techniques in recommendation systems. In R. K. Shukla, A. Malik, & V. Singh (Eds.), *Data, Engineering and Applications* (pp. 11–21). Springer. https://doi.org/10.1007/978-981-13-6347-4_2

Raji, M. A., Olodo, H. B., Oke, T. T., Addy, W. A., Ofodile, O. C., & Oyewole, A. T. (2024). E-commerce and consumer behavior: A review of AI-powered personalization and market trends. *GSC Advanced Research and Reviews*, 18(3), 66-77. <https://doi.org/10.30574/gscarr.2024.18.3.0090>

Rayport, J. F., & Sviokla, J. J. (1995). Exploiting the Virtual Value Chain. *Harvard Business Review*, 73(6), 75-85.

Rebuy (2022, Junio 1). The Amazon Effect: Using Personalization to Generate Billions. *Rebuy*. <https://www.rebuyengine.com/blog/the-amazon-effect>

Retta, L. (s.f.). Two decades in the making – the powerful strategies behind the Amazon recommendation engine. *XP² by Dynamic Yield*. <https://www.dynamicsyield.com/article/amazon-recommendations/>

Ricci, F., Rokach, L., & Shapira, B. (Eds.). (2015). *Recommender systems handbook* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4899-7637-6>

- Ritala, P., Golnam, A., & Wegmann, A. (2014). Coopetition-based business models: The case of Amazon.com. *Industrial Marketing Management*, 43(2), 236-249. <https://doi.org/10.1016/j.indmarman.2013.11.005>.
- Ruiz, A. (2023, Junio 5). Qué es el GMV: Una métrica cada vez más usada por los grandes marketplaces. *Marketing4eCommerce*. <https://marketing4ecommerce.net/que-es-gmv/>
- Sadq, Z. M., Sabir, H. N., & Saeed, V. S. H. (2018). Analyzing the Amazon Success Strategies. *Journal of Process Management – New Technologies*, 6(4), 65-67. <https://doi.org/10.5937/jouproman6-19264>
- Salesforce. (s.f.). *El machine learning: Una visión general*. <https://www.salesforce.com/es/resources/definition/machine-learning/>
- Santander | Impulsa Empresa. (s.f.). *Marketplace: Qué es y cómo funciona*. <https://www.impulsa-empresa.es/marketplace-que-es-como-funciona/>
- SAP. (s.f.). *¿Qué es Machine Learning?* <https://www.sap.com/spain/products/artificial-intelligence/what-is-machine-learning.html>
- Saunders, M., Lewis, P., & Thornhill, A. (2019). *Research methods for business students* (8th ed.). Pearson Education.
- Schafer, J. B., Konstan, J. A., & Riedl, J. (1999). Recommender systems in e-commerce. *Communications of the ACM*, 42(8), 137-143. <https://doi.org/10.1145/336992.337035>
- Schafer, J. B., Konstan, J. A., & Riedl, J. (2001). E-commerce recommendation applications. *Data Mining and Knowledge Discovery*, 5(1), 115–153. <https://doi.org/10.1007/978-1-4899-7637-6>
- Shingala, N. (2020, Diciembre 7). 5 Types of Marketplace Business Models That Work in 2021. *Medium*. <https://medium.com/@nikunjshingala/5-types-of-marketplace-business-models-that-work-in-2021-aaa39dc130eb>
- Siegel, E. (2016). *Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die* (Revised ed.). Wiley.
- Smith, B., & Linden, G. (2017). Two decades of recommender systems at Amazon.com. *IEEE Internet Computing*, 21(3), 12-18. <https://doi.org/10.1109/MIC.2017.33>

Statista. (2023). Ranking de marketplaces online con mayor tasa de penetración entre los consumidores en España en 2023. *Statista*. <https://es.statista.com/estadisticas/637937/marketplaces-online-con-mayor-penetracion-entre-los-consumidores-en-espana/>

Stock Analysis. (s.f.). Amazon.com, Inc. (AMZN) Market Cap. *Stock Analysis*. <https://stockanalysis.com/stocks/amzn/market-cap/>

Stripe. (2023, Septiembre 26). Catorce métricas clave de los marketplaces: qué significan y cómo convertirlas en conocimientos aplicables. *Stripe*. <https://stripe.com/es/resources/more/14-key-marketplace-metrics#:~:text=En%20el%20contexto%20de%20los,a%20cabo%20en%20la%20plataforma>

Tapia Arrate, C. (2001). Los marketplaces electrónicos. *PWC Consulting*. Recuperado de: https://cdn5.icemd.com/app/uploads/2018/12/marketplaces_electronicos.pdf

The Economist. (2012, Marzo 3). Taking the long view. *The Economist*. <https://www.economist.com/technology-quarterly/2012/03/03/taking-the-long-view>

Thorat, P. B., Goudar, R. M., & Barve, S. (2015). Survey on collaborative filtering, content-based filtering and hybrid recommendation system. *International Journal of Computer Applications*, 110(4), 31-36. <http://dx.doi.org/10.5120/19308-0760>

Tiwana, A. (2014). "Platform Ecosystems: Aligning Architecture, Governance, and Strategy." *Morgan Kaufmann*.

Tomas, D. (2024, Abril 27). Tasa de devoluciones en ecommerce: definición, cálculo y estrategias para reducirla. *Cyberclick*. <https://www.cyberclick.es/que-es/tasa-de-devoluciones-ecommerce#:~:text=La%20tasa%20de%20devolución%20es,como%20la%20satisfacción%20del%20cliente>

Trabelsi, F. Z., Khtira, A., & El Asri, B. (2021). *Hybrid recommendation systems: A state of art*. In *Proceedings of the 16th International Conference on Evaluation of Novel Approaches to Software Engineering (ENASE 2021)*, 281-288. SCITEPRESS. <https://doi.org/10.5220/0010452202810288>

Van der Heijden, H. (2004). User acceptance of hedonic information systems. *MIS Quarterly*, 28(4), 695-704. <https://doi.org/10.2307/25148660>

Van Heusden, A. (2023). *Algorithmic pricing: The current state of affairs from a law and economics perspective*. In *Dret*, 3, 329-348. <https://doi.org/10.31009/InDret.2023.i3.08>

Villalonga, R. (2021, Abril 28). *Sistemas recomendadores basados en contenido*. Medium. <https://medium.com/@rvillalongar/sistemas-recomendadores-basados-en-contenido-ece0227e7005>

Xiao, B., & Benbasat, I. (2007). E-commerce product recommendation agents: Use, characteristics, and impact. *MIS Quarterly*, 31(1), 137-209. <https://www.jstor.org/stable/25148784>

Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), 1-38. <https://doi.org/10.1145/3285029>

Zhang, X., Guo, F., Chen, T., Pan, L., Beliakov, G., & Wu, J. (2023). A brief survey of machine learning and deep learning techniques for e-commerce research. *Journal of Theoretical and Applied Electronic Commerce Research*, 18(4), 2188–2216. <https://doi.org/10.3390/jtaer18040110>

Zhou, B., & Zou, T. (2023). Competing for recommendations: The strategic impact of personalized product recommendations in online marketplaces. *Marketing Science*, 42(2), 360-376. <https://doi.org/10.1287/mksc.2022.1388>

Zhou, H., Xiong, F., & Chen, H. (2023). A comprehensive survey of recommender systems based on deep learning. *Applied Sciences*, 13(20), 11378. <https://doi.org/10.3390/app132011378>

ANEXO I: Cuestionario

1. ¿Cuál es tu edad? [Opción múltiple]

- Menos de 18 años
- Entre 18 y 24 años
- Entre 25 y 34 años
- Entre 35 y 44 años
- Entre 45 y 54 años
- Entre 55 y 64 años
- 65 años o más

2. ¿Cuál es tu situación laboral? [Opción múltiple]

- Trabajador
- Estudiante
- Parado
- Jubilado
- Otra (especificar): _____

¡Hola! Estoy realizando un estudio para analizar el impacto de los sistemas de recomendación de Amazon en los consumidores. En este cuestionario, se entiende por "recomendaciones" aquellos elementos sugeridos por Amazon como productos similares a lo que has buscado o comprado, reseñas y valoraciones de otros usuarios, productos destacados en tu página de inicio o los más vendidos. Tus respuestas serán anónimas y se usarán exclusivamente con fines de investigación. ¡Gracias por tu participación!

3. ¿Eres cliente de Amazon?

- Sí (sigue adelante en el cuestionario)
- No (fin del cuestionario)

4. ¿Con qué frecuencia compras en Amazon? [Opción múltiple]

- Raramente (una vez al año)
- Ocasionalmente (una vez cada 3-6 meses)
- Moderadamente (una vez al mes)
- Frecuentemente (dos o tres veces al mes)
- Muy frecuentemente (una vez a la semana o más)

5. ¿Alguna vez has comprado un producto recomendado por Amazon?

- Sí
- No

6. ¿Con qué frecuencia consideras las recomendaciones de Amazon antes de realizar una compra?

	Nunca	Raramente	A veces	Frecuentemente	Siempre
- Reseñas o comentarios de otros usuarios	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Valoraciones o estrellas	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Similar a lo que has buscado anteriormente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Comprados anteriormente por ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Los más vendidos	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Ofertas para ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Sugerencias de la página de inicio	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

7. ¿Cómo de relevantes te parecen cada una de las siguientes recomendaciones? Donde “1” es nada relevantes y “5” muy relevantes [Escala numérica 1-5]

	1	2	3	4	5
- Reseñas o comentarios de otros usuarios	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Valoraciones o estrellas	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Similar a lo que has buscado anteriormente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Comprados anteriormente por ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Los más vendidos	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Ofertas para ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Sugerencias de la página de inicio	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

8. Hasta qué punto estás de acuerdo con la siguiente información: “Las recomendaciones de Amazon reflejan mis gustos personales” Donde “1” es para nada de acuerdo y “5” muy de acuerdo [Escala numérica 1-5]

	1	2	3	4	5
- Reseñas o comentarios de otros usuarios	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Valoraciones o estrellas	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Similar a lo que has buscado anteriormente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Comprados anteriormente por ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Los más vendidos	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Ofertas para ti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
- Sugerencias de la página de inicio	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

9. ¿Cuáles de los siguientes beneficios valoras más en las recomendaciones que te ofrece Amazon? Selecciona todas las que apliquen. [Opción múltiple]

- Me ayuda a descubrir nuevos productos que podrían interesarme
- Me ahorra tiempo al no tener que buscar alternativas
- Las recomendaciones representan bien mis intereses y preferencias
- Facilita mi proceso de compra
- Me inspira y da ideas para futuras compras
- Mejora mi experiencia general en la plataforma
- Otro (especificar): _____

10. ¿Te gustaría recibir recomendaciones basadas en productos guardados o compartidos en un tablero colaborativo con amigos o familiares?

Imagina que estás organizando una fiesta con tus amigos y todos comparten un tablero colaborativo en Amazon donde añaden cosas que les gustaría incluir, como decoraciones, comida, y accesorios. Podrías ver las recomendaciones de tus amigos a la vez que Amazon podría sugerir ideas adicionales, como luces de fiesta o productos complementarios a los que ya están en el tablero.

- Sí
- No
- Tal vez

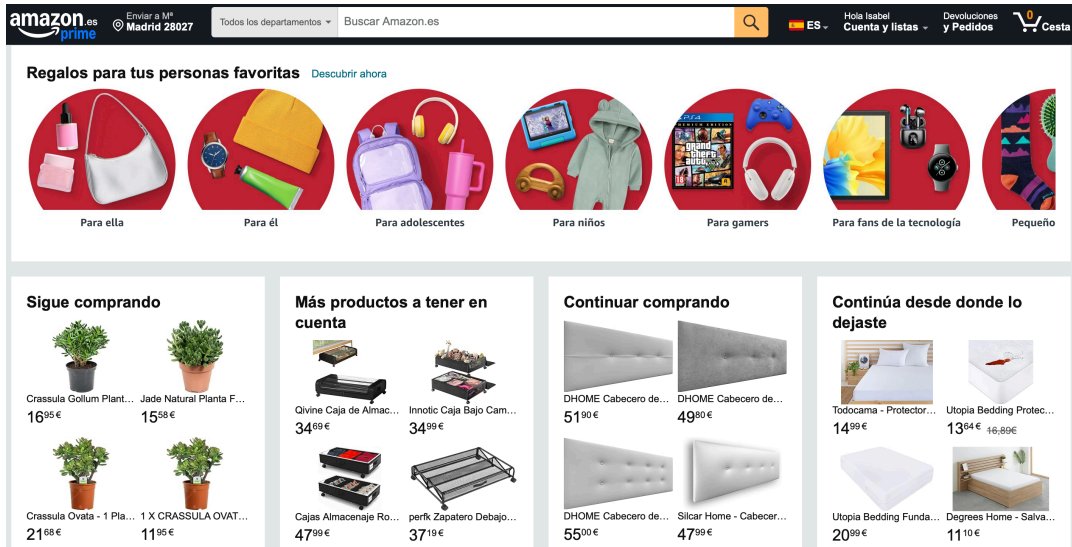
11. ¿Interactuarías con un espacio en Amazon donde pudieras ver y compartir listas de productos recomendados con amigos o familiares? Donde "1" es "nada probable" y "5" es "muy probable". [Escala numérica 1-5]

- 1 = "Nada probable"
- 2 = "Poco probable"
- 3 = "Algo probable"
- 4 = "Bastante probable"
- 5 = "Muy probable"

12. ¿Crees que las recomendaciones personalizadas mejoran tu experiencia de compra en Amazon? Donde "1" es "no mejoran para nada mi experiencia" y "5" es "mejoran mi experiencia significativamente". [Escala numérica 1-5]

- 1 = "No mejoran para nada mi experiencia"
- 2 = "Mejoran poco mi experiencia"
- 3 = "Mejoran algo mi experiencia"
- 4 = "Mejoran bastante mi experiencia"
- 5 = "Mejoran mucho mi experiencia"

13. ¿Consideras que la disposición y el orden de las recomendaciones en la página de Amazon es adecuado? *[Escala de Likert]*



- Es muy adecuada
- Es adecuada
- Me es indiferente
- Es inadecuada
- Es muy inadecuada

14. ¿Cómo calificarías la experiencia de navegación al usar las recomendaciones de Amazon? Donde "1" es "muy insatisfactoria y muy poco intuitiva" y "5" es "muy satisfactoria y muy intuitiva". *[Escala numérica 1-5]*

- 1 = "Muy insatisfactoria y muy poco intuitiva"
- 2 = "Insatisfactoria y poco intuitiva"
- 3 = "Indiferente"
- 4 = "Bastante satisfactoria e intuitiva"
- 5 = "Muy satisfactoria y muy intuitiva"

15. ¿Te gustaría ver una sección donde Amazon te permita personalizar tus preferencias para recibir recomendaciones más acertadas?

Piensa en una función en la que pudieras indicar a Amazon que estás buscando productos para organizar una fiesta temática, como una "fiesta de los años 80". Podrías seleccionar tus preferencias, como el tipo de decoraciones, ropa, y música, y Amazon te mostraría recomendaciones específicas basadas en estas elecciones.

- Sí
- No
- Tal vez

16. ¿Te gustaría que las recomendaciones de Amazon incluyeran opciones de personalización más avanzadas, como la posibilidad de excluir ciertos tipos de productos o categorías?

Supongamos que estás buscando artículos para tus próximas vacaciones en una isla paradisíaca y no quieres que Amazon te muestre productos relacionados con esquí. Podrías configurar tus preferencias para excluir ese tipo de productos, y Amazon ajustaría sus recomendaciones para mostrar solo lo que necesitas.

- Sí
- No
- Tal vez

17. ¿Te interesaría recibir recomendaciones basadas en eventos o tendencias de tus redes sociales (con tu permiso)?

Imagina que en tus redes sociales publicaste que te vas de vacaciones a Australia. Con tu permiso, Amazon podría identificar esta información y sugerirte guías de viaje, adaptadores específicos para el país, o productos populares que otros usuarios que viajan a Australia suelen comprar.

- Sí
- No
- Tal vez

18. ¿Qué características te gustaría que Amazon añadiera para mejorar sus recomendaciones? Selecciona todas las que apliquen.

- Opción para personalizar las recomendaciones según mis intereses y necesidades específicas
- Tableros colaborativos donde amigos o familiares puedan compartir recomendaciones y listas de deseos
- Función para eliminar o marcar productos no deseados en las recomendaciones
- Recomendaciones basadas en tendencias o eventos relevantes (p. ej., fiestas, estaciones...)
- Mejores opciones para explorar productos de categorías nuevas o menos conocidas
- Más recomendaciones basadas en productos similares a los que ya he comprado
- Otro (especificar): _____

19. ¿Qué cambios harías en la manera en que Amazon te presenta las recomendaciones? Selecciona todas las que apliquen.

- Reorganizar las recomendaciones para priorizar mis categorías de productos favoritas
- Incluir más detalles o contextos (p. ej., por qué se recomienda el producto), explicar mejor cómo se generan las recomendaciones
- Permitir opciones de filtrado en las recomendaciones (p. ej., rango de precio, categoría)
- Ofrecer recomendaciones de productos populares en mi zona geográfica
- Cambiar la frecuencia con la que aparecen nuevas recomendaciones
- Modificar el diseño de la plataforma para hacerla visualmente más atractiva.
- Otro (especificar): _____


20. ¿Has tenido alguna experiencia específica con las recomendaciones de Amazon que quieras compartir? Selecciona todas las que apliquen.

- Me han ayudado a descubrir productos nuevos y relevantes para mis intereses
- Me han facilitado el proceso de compra al mostrar productos relacionados
- Las recomendaciones suelen ser poco relevantes para mis intereses
- A veces las recomendaciones son repetitivas y no cambian con frecuencia
- Las recomendaciones de productos comprados anteriormente no son útiles
- Las recomendaciones me han inspirado a realizar compras inesperadas
- Otro (especificar): _____

ANEXO II: Resultados del Cuestionario


1. ¿Cuál es tu edad?

Edad	Recuento	%
Menos de 18 años	0	0%
Entre 18 y 25 años	16	15%
Entre 25 y 34 años	28	27%
Entre 35 y 44 años	22	21%
Entre 45 y 54 años	26	25%
Entre 55 y 64 años	7	7%
65 años o más	6	6%
TOTAL	105	100%




2. ¿Cuál es tu situación laboral?

Situación Laboral	Recuento	%
Trabajador	75	71%
Estudiante	20	19%
Parado	3	3%
Jubilado	7	7%
TOTAL	105	100%



3. ¿Eres cliente de Amazon?


Cliente Amazon	Recuento	%
Sí	105	87%
No	16	13%
TOTAL	121	100%



4. ¿Con qué frecuencia compras en Amazon?

Frecuencia de Compra en Amazon	Recuento	%
Raramente (una vez al año)	7	7%
Ocasionalmente (una vez cada 3-6 meses)	34	32%
Moderadamente (una vez al mes)	35	33%
Frecuentemente (dos o tres veces al mes)	22	21%
Muy frecuentemente (una vez a la semana o más)	7	7%
TOTAL	105	100%


¿Con qué frecuencia compras en Amazon?



5. ¿Alguna vez has comprado un producto recomendado por Amazon?

¿Comprado producto recomendado por Amazon?	Recuento	%
Sí	86	82%
No	19	18%
TOTAL	105	100%


¿Alguna vez has comprado un producto recomendado por Amazon?



6. ¿Con qué frecuencia consideras las recomendaciones de Amazon antes de realizar una compra?


Frecuencia de Consideración de las Recomendaciones	Nunca	Raramente	A veces	Frecuentemente	Siempre	TOTAL
Reseñas o comentarios de otros usuarios	0	2	24	41	38	105
Valoraciones o estrellas	0	4	23	37	41	105
Similar a lo que has buscado anteriormente	4	7	33	49	12	105
Comprados anteriormente por ti	3	13	35	47	7	105
Los más vendidos	7	16	28	37	17	105
Ofertas para ti	3	29	33	30	10	105
Sugerencias de la página de inicio	24	39	26	14	2	105

¿Con qué frecuencia consideras las recomendaciones de Amazon antes de realizar una compra?



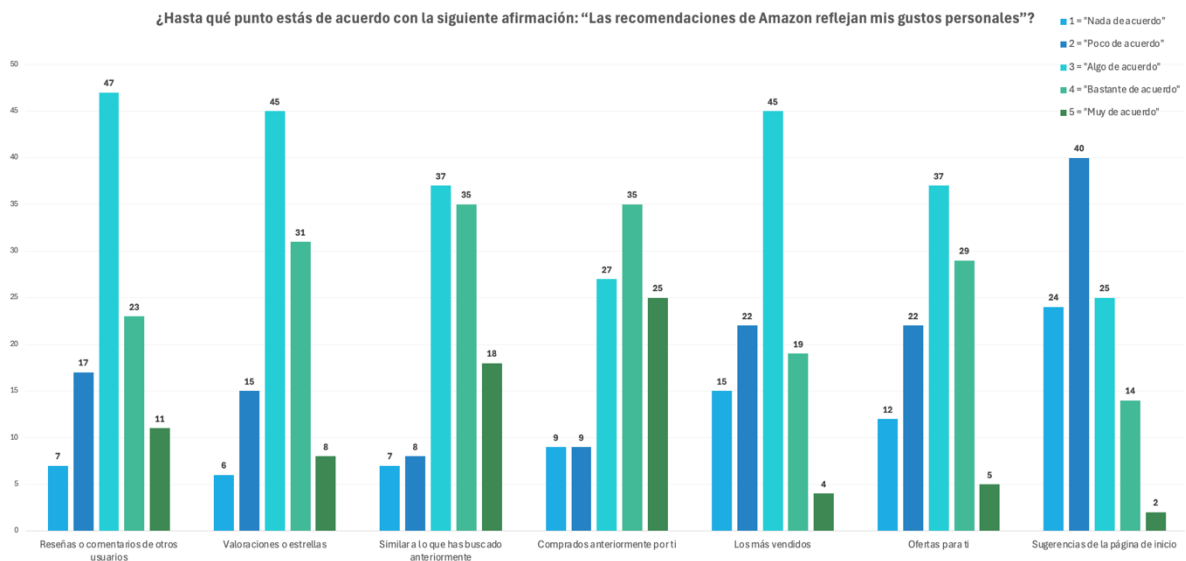
7. ¿Cómo de relevantes te parecen cada una de las siguientes recomendaciones? Donde “1” es nada relevantes y “5” muy relevantes.

Percepción de Relevancia de las Recomendaciones	1 = "Nada relevantes"	2 = "Poco relevantes"	3 = "Algo Relevantes"	4 = "Bastante Relevantes"	5 = "Muy relevantes"	TOTAL	PROMEDIO
Reseñas o comentarios de otros usuarios	1	5	8	31	60	105	4,37
Valoraciones o estrellas	1	5	10	35	54	105	4,30
Similar a lo que has buscado anteriormente	4	8	34	44	15	105	3,55
Comprados anteriormente por ti	5	6	29	38	27	105	3,72
Los más vendidos	13	10	40	27	15	105	3,20
Ofertas para ti	8	20	42	28	7	105	3,06
Sugerencias de la página de inicio	36	26	32	8	3	105	2,20
							3,49



8. Hasta qué punto estás de acuerdo con la siguiente información: “Las recomendaciones de Amazon reflejan mis gustos personales” Donde “1” es para nada de acuerdo y “5” muy de acuerdo.


Percepción de Alineación entre Gustos y Recomendaciones	1 = "Nada de acuerdo"	2 = "Poco de acuerdo"	3 = "Algo de acuerdo"	4 = "Bastante de acuerdo"	5 = "Muy de acuerdo"	TOTAL	PROMEDIO
Reseñas o comentarios de otros usuarios	7	17	47	23	11	105	3,13
Valoraciones o estrellas	6	15	45	31	8	105	3,19
Similar a lo que has buscado anteriormente	7	8	37	35	18	105	3,47
Comprados anteriormente por ti	9	9	27	35	25	105	3,55
Los más vendidos	15	22	45	19	4	105	2,76
Ofertas para ti	12	22	37	29	5	105	2,93
Sugerencias de la página de inicio	24	40	25	14	2	105	2,33
							3,05



9. ¿Cuáles de los siguientes beneficios valoras más en las recomendaciones que te ofrece Amazon? *Selecciona todas las que apliquen.*

Beneficios más valorados	Recuento	%
Me ayuda a descubrir nuevos productos que podrían interesarme	48	46%
Me ahorra tiempo al no tener que buscar alternativas	67	64%
Las recomendaciones representan bien mis intereses y preferencias	10	10%
Facilita mi proceso de compra	68	65%
Me inspira y me da ideas para futuras compras	39	37%
Mejora mi experiencia general en la plataforma	37	35%
"No lo valoro"	1	1%
"No tengo en cuenta las recomendaciones"	1	1%


¿Cuáles de los siguientes beneficios valoras más en las recomendaciones que te ofrece Amazon?



10. ¿Te gustaría recibir recomendaciones basadas en productos guardados o compartidos en un tablero colaborativo con amigos o familiares?

¿Te gustaría recibir recomendaciones basadas en productos guardados o compartidos en un tablero colaborativo con amigos o familiares?


Interés en Tablero Colaborativo	Recuento	%
Sí	48	46%
No	37	35%
Tal vez	20	19%
TOTAL	105	100%



11. ¿Interactuarías con un espacio en Amazon donde pudieras ver y compartir listas de productos recomendados con amigos o familiares? Donde "1" es "nada probable" y "5" es "muy probable".

Probabilidad de Interactuar con Tablero Colaborativo	Recuento	%
1 = "Nada probable"	15	14%
2 = "Poco probable"	10	10%
3 = "Algo probable"	13	12%
4 = "Bastante probable"	39	37%
5 = "Muy probable"	28	27%
TOTAL	105	100%

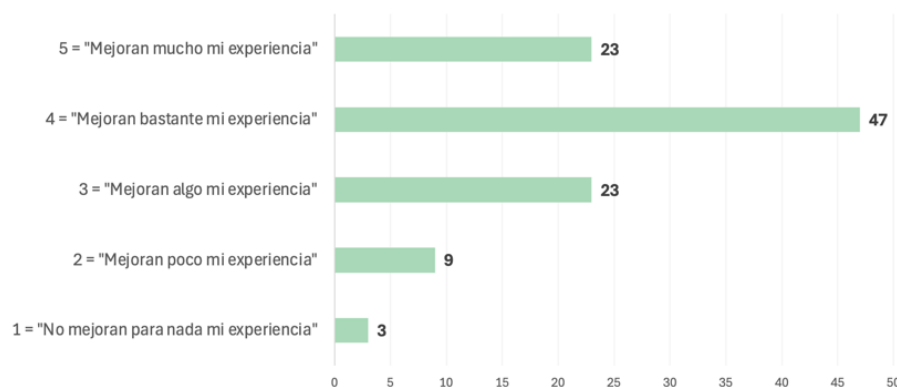
¿Interactuarías con un espacio en Amazon donde pudieras ver y compartir listas de productos recomendados con amigos o familiares?




12. ¿Crees que las recomendaciones personalizadas mejoran tu experiencia de compra en Amazon? Donde "1" es "no mejoran para nada mi experiencia" y "5" es "mejoran mi experiencia significativamente".

Percepción de Mejora de Experiencia gracias a Recomendaciones	Recuento	%
1 = "No mejoran para nada mi experiencia"	3	3%
2 = "Mejoran poco mi experiencia"	9	9%
3 = "Mejoran algo mi experiencia"	23	22%
4 = "Mejoran bastante mi experiencia"	47	45%
5 = "Mejoran mucho mi experiencia"	23	22%
TOTAL	105	100%

¿Crees que las recomendaciones personalizadas mejoran tu experiencia de compra en Amazon?




13. ¿Consideras que la disposición y el orden de las recomendaciones en la página de Amazon es adecuado?



14. ¿Cómo calificarías la experiencia de navegación al usar las recomendaciones de Amazon? Donde "1" es "muy insatisfactoria y muy poco intuitiva" y "5" es "muy satisfactoria y muy intuitiva".


Percepción Experiencia de Navegación	Recuento	%
1 = "Muy insatisfactoria y muy poco intuitiva"	1	1%
2 = "Insatisfactoria y poco intuitiva"	14	13%
3 = "Indiferente"	47	45%
4 = "Bastante satisfactoria e intuitiva"	36	34%
5 = "Muy satisfactoria y muy intuitiva"	7	7%
TOTAL	105	100%



15. ¿Te gustaría ver una sección donde Amazon te permita personalizar tus preferencias para recibir recomendaciones más acertadas?

¿Te gustaría ver una sección donde Amazon te permita personalizar tus preferencias para recibir recomendaciones más acertadas?


Interés en Personalizar Preferencias	Recuento	%
Sí	56	53%
No	11	10%
Tal vez	38	36%
TOTAL	105	100%



16. ¿Te gustaría que las recomendaciones de Amazon incluyeran opciones de personalización más avanzadas, como la posibilidad de excluir ciertos tipos de productos o categorías?

¿Te gustaría que las recomendaciones de Amazon incluyeran opciones de personalización más avanzadas, como la posibilidad de excluir ciertos tipos de productos o categorías?


Interés en Personalización Avanzada (ej. Filtros excluyentes)	Recuento	%
Sí	54	51%
No	10	10%
Tal vez	41	39%
TOTAL	105	100%



17. ¿Te interesaría recibir recomendaciones basadas en eventos o tendencias de tus redes sociales (con tu permiso)?

¿Te interesaría recibir recomendaciones basadas en eventos o tendencias de tus redes sociales (con tu permiso)?

Interés en Recomendaciones basadas en Actividad en Redes Sociales	Recuento	%
Sí	24	23%
No	51	49%
Tal vez	30	29%
TOTAL	105	100%



18. ¿Qué características te gustaría que Amazon añadiera para mejorar sus recomendaciones? Selecciona todas las que apliquen

Características a añadir en las recomendaciones	Recuento	%
Opción para personalizar las recomendaciones según mis intereses y necesidades específicas	64	61%
Tableros colaborativos donde amigos o familiares puedan compartir recomendaciones y listas de deseos	63	60%
Función para eliminar o marcar productos no deseados en las recomendaciones	52	50%
Recomendaciones basadas en tendencias o eventos relevantes (p. ej., fiestas, estaciones...)	25	24%
Mejores opciones para explorar productos de categorías nuevas o menos conocidas	41	39%
Más recomendaciones basadas en productos similares a los que ya he comprado	22	21%
"Nada"	1	1%


¿Qué características te gustaría que Amazon añadiera para mejorar sus recomendaciones?



19. ¿Qué cambios harías en la manera en que Amazon te presenta las recomendaciones? Selecciona todas las que apliquen.

Cambios en la manera en que Amazon presenta sus recomendaciones	Recuento	%
Reorganizar las recomendaciones para priorizar mis categorías de productos favoritas	60	57%
Incluir más detalles o contextos (p. ej., por qué se recomienda el producto) y explicar mejor cómo se generan las recomendaciones	26	25%
Permitir opciones de filtrado avanzadas en las recomendaciones (p. ej., rango de precio, categoría)	69	66%
Ofrecer más recomendaciones de productos populares en mi zona geográfica	12	11%
Cambiar la frecuencia con la que aparecen nuevas recomendaciones	25	24%
Modificar el diseño de la plataforma para hacerla visualmente más atractiva	38	36%
"Ninguna"	1	1%

¿Qué cambios harías en la manera en que Amazon te presenta las recomendaciones?



20. ¿Has tenido alguna experiencia específica con las recomendaciones de Amazon que quieras compartir? Selecciona todas las que apliquen.

Experiencias con las recomendaciones de Amazon	Recuento	%
Me han ayudado a descubrir productos nuevos y relevantes para mis intereses	40	38%
Me han facilitado el proceso de compra al mostrar productos relacionados	51	49%
Las recomendaciones suelen ser poco relevantes para mis intereses	19	18%
A veces las recomendaciones son repetitivas y no cambian con frecuencia	39	37%
Las recomendaciones de productos comprados anteriormente no son útiles	14	13%
Las recomendaciones me han inspirado a realizar compras inesperadas	31	30%
"No"	1	1%
"No sé"	1	1%
"Tiendas falsas con artículos engañosos"	1	1%

¿Has tenido alguna experiencia positiva o negativa específica con las recomendaciones de Amazon que quieras compartir?

