



Facultad de Ciencias Económicas y Empresariales
ICADE

**EL SISTEMA NO NIVELA,
ESTRATIFICA: ASIMETRÍA
COMPETITIVA Y BARRERAS
ESTRUCTURALES DEL MACHINE
LEARNING EN LOS
MARKETPLACES B2C.**

Autor: Fernando Lapetra Murcia
Director: María Olga Bocigas Solar

MADRID | junio de 2026

RESUMEN

Este trabajo analiza el proceso de Machine Learning aplicado a la publicidad automatizada en Marketplaces B2C para determinar en qué medida genera ventajas competitivas asimétricas y sostenidas entre los actores que participan en él. Frente al discurso dominante que presenta estos sistemas como democratizadores del acceso al mercado digital, el análisis demuestra que la arquitectura del pipeline introduce seis barreras estructurales encadenadas: granularidad del dato, capacidad técnica y volumen, volumen de ejemplos etiquetados, presupuesto experimental, volumen de tráfico mínimo y apropiación del aprendizaje que condicionan de forma progresiva la posición competitiva de cada actor. Apoyándose en el marco VRIO de Barney (1991) y en el concepto de path dependence de Arthur (1989), el trabajo argumenta que estas barreras no son temporales ni corregibles con mayor inversión, sino estructurales: los recursos necesarios para mitigarlas son inimitables y la dinámica de refuerzo acumulativo amplía la brecha entre actores con el tiempo en lugar de reducirla. A partir de este análisis se propone el concepto de espectro de apropiación diferencial, que clasifica a los actores no por su tamaño sino por su capacidad real de acceder a las distintas fases del pipeline. En el extremo del espectro se encuentra la plataforma, único actor que controla el ciclo completo y se apropia del aprendizaje generado por todos los demás. El resultado es un sistema que, bajo una apariencia de acceso igualitario, reproduce y amplifica las asimetrías estructurales entre quienes lo usan.

Palabras clave: Machine Learning, publicidad automatizada, Marketplaces B2C, barreras estructurales, ventaja competitiva, path dependence, VRIO, apropiación diferencial, aprendizaje por refuerzo, predicción de CTR.

ABSTRACT

This paper analyses the Machine Learning pipeline applied to automated advertising in B2C Marketplaces to determine the extent to which it generates asymmetric and sustained competitive advantages among the actors involved. Against the prevailing narrative that presents these systems as democratising tools for digital market access, the analysis shows that the pipeline architecture introduces six chained structural barriers data granularity, technical capacity and volume, labelled example volume, experimental budget, minimum traffic volume, and learning appropriation that progressively condition the competitive position of each actor. Drawing on Barney's (1991) VRIO framework and Arthur's (1989) concept of path dependence, the paper argues that these barriers are not temporary or correctable through greater investment, but structural: the resources needed to mitigate them are inimitable, and the cumulative reinforcement dynamic widens the gap between actors over time rather than narrowing it. Building on this analysis, the paper proposes the concept of a differential appropriation spectrum, which classifies actors not by size but by their actual capacity to access the different phases of the pipeline. At one extreme of the spectrum sits the platform itself, the only actor that controls the complete cycle and appropriates the learning generated by all others. The result is a system that, beneath an appearance of equal access, reproduces and amplifies structural asymmetries among those who use it.

Keywords: Machine Learning, automated advertising, B2C Marketplaces, structural barriers, competitive advantage, path dependence, VRIO, differential appropriation, reinforcement learning, CTR prediction.

ÍNDICE

CAPÍTULO 1. INTRODUCCIÓN	8
1.1 Objetivo general.....	8
1.2 Metodología.....	9
1.3 Justificación del tema	10
1.4 Estructura del trabajo.....	11
CAPÍTULO 2. BASES DE LA PUBLICIDAD EN MARKETPLACES B2C	12
2.1 Qué es un Marketplace y sus tipos	12
2.2 El Marketplace como entorno publicitario cerrado	13
2.3 Bases de la publicidad automatizada: formatos, ubicaciones y objetivos en Marketplace B2C	15
2.4 El proceso de asignación del espacio: subastas, pujas y el modelo CPC.....	16
2.5 Métricas	17
2.6 Por qué se automatiza.....	19
2.7 Las asimetrías estructurales de la cadena de procesamiento.....	20
CAPÍTULO 3. LA INFORMACIÓN COMO BASE DE LA AUTOMATIZACIÓN	22
3.1 Tipos de señales y datos	22
3.2 Valor predictivo	23
3.3 Limitaciones y retos del dato.....	24
CAPÍTULO 4. FASE 1: FASE DE RECOGIDA	25
4.1 Mecanismos de captura	25
4.2 Infraestructura y desafíos operativos.....	26
4.3 Implicaciones competitivas de la fase.....	28
CAPÍTULO 5. FASE 2: PREPARACIÓN Y ESTRUCTURACIÓN DE DATOS	28
5.1 Limpieza y validación	28
5.2 Ingeniería de variables	28
5.3 Modelos no supervisados.....	30
5.4 Modelos supervisados	30
5.5 Implicaciones competitivas de la fase.....	31
CAPÍTULO 6. FASE 3: MODELIZACIÓN PREDICTIVA	31
6.1 Problema de predicción: pCTR, pCVR y sesgo de selección	31
6.2 Evolución de modelos: tres generaciones.....	32
6.3 Métricas de evaluación: por qué la precisión siempre engaña.....	33
6.4 Implicaciones competitivas de la fase.....	34
CAPÍTULO 7. FASE 4: OPTIMIZACIÓN Y TOMA DE DECISIONES	34

7.1 El problema de la puja como decisión secuencial	35
7.2 Multi-Armed Bandits y aprendizaje por refuerzo profundo	35
7.3 Implicaciones competitivas de la fase.....	36
CAPÍTULO 8. FASE 5: PERSONALIZACIÓN Y CREATIVIDADES DINÁMICAS.	37
8.1 Selección dinámica y experimentación.....	37
8.2 Modelos generativos	37
8.3 Implicaciones competitivas de la fase.....	38
CAPÍTULO 9. FASE 6: RETROALIMENTACIÓN Y APRENDIZAJE CONTINUO	38
9.1 Online y Batch learning.....	38
9.2 Concept drift y recalibración	39
9.3 Implicaciones competitivas de la fase.....	39
CAPÍTULO 10: EL PIPELINE COMO MECANISMO DE APROPIACIÓN DIFERENCIAL	39
10.1 Las seis barreras como sistema encadenado.....	40
CAPÍTULO 11. CONCLUSIONES, LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN.	41
11.1 Conclusiones	41
11.2 Limitaciones.....	43
11.3 Futuras líneas de investigación	44
DECLARACIÓN DE USO DE HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL GENERATIVA EN TRABAJOS FIN DE GRADO	46
BIBLIOGRAFÍA	48

ÍNDICE DE TABLAS

Tabla 1 *Aplicación del marco VRIO a los datos propios de los Marketplaces líderes.*

Tabla 2 *Los cuatro mecanismos de captura de eventos en sistemas de publicidad automatizada*

Tabla 3 *Comparación entre puja estática y puja con aprendizaje por refuerzo*

Tabla 4 *Las seis barreras estructurales de la cadena de procesamiento publicitario en Marketplaces B2C*

ÍNDICE DE FIGURAS

Figura 1 *El pipeline de Machine Learning como ciclo de mejora continua*

Figura 2 *Construcción del vector de características: de la señal bruta a la predicción*

Figura 3 *Evolución de los modelos de predicción de CTR y CVR: tres generaciones.*

LISTA DE SIGLAS Y ABREVIATURAS

ACoS	Advertising Cost of Sale - ratio de coste publicitario sobre ventas
ATT	App Tracking Transparency - sistema de consentimiento de rastreo de Apple
AUC-ROC	Area Under the Curve - Receiver Operating Characteristic - métrica de evaluación de modelos de clasificación
B2B	Business to Business - modelo de negocio entre empresas
B2C	Business to Consumer - modelo de negocio entre empresa y consumidor final
C2C	Consumer to Consumer - modelo de negocio entre particulares
CPC	Coste por clic
CRM	Customer Relationship Management - gestión de relaciones con clientes
CTR	Click-Through Rate - tasa de clics
CVR	Conversion Rate - tasa de conversión
DeepFM	Deep Factorization Machine - arquitectura de red neuronal profunda para predicción de CTR
DLRM	Deep Learning Recommendation Model - arquitectura de red neuronal profunda desarrollada en Meta
DMA	Digital Markets Act - reglamento europeo sobre mercados digitales
DSP	Demand-Side Platform - plataforma de compra de publicidad programática
GDPR	General Data Protection Regulation - Reglamento General de Protección de Datos de la Unión Europea
GAID	Google Advertising ID - identificador publicitario en dispositivos Android
GIVT	General Invalid Traffic - tráfico no humano detectable mediante filtros rutinarios
IAB	Interactive Advertising Bureau - organismo de estándares de la industria publicitaria digital
IDFA	Identifier for Advertisers - identificador publicitario en dispositivos iOS de Apple
KNN	K-Nearest Neighbours - algoritmo de clasificación basado en los k-vecinos más próximos

MAB	Multi-Armed Bandit - marco de decisión secuencial del aprendizaje por refuerzo
ML	Machine Learning - aprendizaje automático
MRC	Media Rating Council - organismo de estándares de medición en publicidad digital
PCA	Principal Component Analysis - Análisis de Componentes Principales
pCTR	Probabilidad estimada de clic
pCVR	Probabilidad estimada de conversión
PPC	Pay Per Click - modelo de pago por clic en publicidad digital
RL	Reinforcement Learning - aprendizaje por refuerzo
ROAS	Return on Advertising Spend - retorno de la inversión publicitaria
SDK	Software Development Kit - kit de desarrollo de software para integración en aplicaciones
SIVT	Sophisticated Invalid Traffic - tráfico no humano de detección compleja que requiere analítica avanzada
UCB	Upper Confidence Bound - algoritmo de exploración en marcos Multi-Armed Bandit
URL	Uniform Resource Locator - dirección de un recurso en internet
VRIO	Valioso, Escaso (Rare), Inimitable, Organización - marco analítico de ventaja competitiva sostenida (Barney, 1991)
Wide & Deep	<i>Wide & Deep</i> - arquitectura de red neuronal profunda propuesta por Google que combina componente lineal y profundo
XGBoost	<i>Extreme Gradient Boosting</i> - implementación eficiente de Gradient Boosting

CAPÍTULO 1. INTRODUCCIÓN

1.1 Objetivo general

El objetivo general de este Trabajo de Fin de Grado será determinar en qué medida el proceso de Machine Learning aplicado a la publicidad automatizada en Marketplace B2C genera ventajas competitivas asimétricas y sostenidas entre los actores que participan en el proceso. Para ello, se analizará cómo se estructuran las distintas fases que componen dicho proceso, identificando qué modelos intervienen en cada etapa. También se estudiará qué requisitos exige cada una en términos de datos, infraestructura y capacidad técnica. A partir del análisis de estos requisitos, este trabajo propone la identificación y sistematización de barreras de acceso a la cadena de procesamiento, permitiendo determinar en qué medida condicionan de forma diferencial la capacidad de apropiación del sistema según el tipo de actor.

Para alcanzar este objetivo, el análisis se desarrolla siguiendo la cadena de procesamiento típica que recorre un sistema de publicidad automatizada. Se divide en seis fases las cuales constituyen seis niveles cuyo acceso diferencial entre actores se examina a lo largo del trabajo. En concreto, se examinan de manera ordenada las fases que lo componen.

El análisis comienza con la fase de recogida y generación de datos, donde se tratan las señales de usuario, producto y contexto que componen las bases sobre las que luego operarán los modelos algorítmicos. La siguiente es la fase de preparación y estructuración cuyo propósito es limpiar y depurar la información, interviniendo aquí técnicas de aprendizaje no supervisado.

A continuación, va la fase de modelización predictiva, destinada a estimar variables clave como la probabilidad de clic, la probabilidad de conversión o el valor esperado, siendo el modelo de aprendizaje supervisado el más destacado. Posteriormente, la fase de optimización y toma de decisiones automática, que se centra en los modelos de aprendizaje por refuerzo para ajustar las pujas, distribuir el presupuesto y decidir estrategias de forma secuencial en tiempo real. Por otro lado, la fase de personalización creativa aplica modelos generativos capaces de seleccionar o adaptar la creatividad publicitaria más adecuada para cada usuario. Finalmente, cabe destacar la fase de retroalimentación la cual cierra todo el ciclo e integra todos los resultados con el fin de optimizar, actualizar y recalibrar los modelos de forma constante y dinámica.

1.2 Metodología

Este trabajo va a tener una metodología de carácter teórico-conceptual que se basará en una revisión bibliográfica sistemática. Como se ha explicado en el objetivo, no se busca construir un modelo propio o hacer un análisis empírico, sino conseguir comprender y explicar todas y cada una de las fases que componen el proceso de Machine Learning aplicado en los Marketplaces, por lo que habrá un apoyo en literatura científica y documentación técnica como bases de datos académicas: Google Scholar, Web of Science, Scopus o EBSCOhost.

Se compararán, sintetizarán y estructurarán todas las fuentes para establecer un marco sólido que explique los conceptos de tal manera que se consiga explicar con precisión y rigor cómo los modelos de Machine Learning intervienen en la publicidad automatizada de los Marketplaces. Para ello se seleccionará una bibliografía desde los criterios de actualidad, relevancia y claridad conceptual.

Para llevar a cabo la búsqueda bibliográfica se usarán *keywords* con vinculación al objeto de estudio. Entre ellas destacan: *machine learning, online advertising, marketplaces, CTR prediction, CVR prediction, supervised learning, unsupervised learning, reinforcement learning, multi-armed bandits, automated bidding systems, programmatic advertising, feature engineering, data pipelines, generative models o personalized advertising*. Su uso estructurado permitirá y facilitará localizar literatura relevante y organizar los distintos capítulos y objetivos.

También se utilizará documentación técnica publicada por plataformas como Amazon Ads, Google Ads y Meta Ads y repositorios para acceder a papers como arXiv. Con estos se velará por complementar la literatura científica y explicar con más claridad los fundamentos operativos de los sistemas.

A su vez, para analizar las implicaciones competitivas de la cadena de procesamiento se requerirá el uso de dos marcos teóricos de disciplinas complementarias a la revisión bibliográfica principal. El primero es el marco VRIO, dentro del ámbito de estrategia empresarial, que permite evaluar si los Marketplaces líderes cuentan con una ventaja competitiva sostenida debido a todos los datos que tienen acumulados (Barney, 1991). Y desde el ámbito de economía industrial se usará el concepto *path dependence* formulado por Arthur (1989). Este explica que dichas ventajas tienden a amplificarse con el paso del tiempo.

1.3 Justificación del tema

Los Marketplaces B2C están adquiriendo cada vez más y más peso dentro del ecosistema comercial global. Son plataformas que son de gran utilidad como un intermediario digital el cual concentra una variedad de productos y vendedores masiva. Para gestionar y organizar todos sus catálogos, usan algoritmos capaces de filtrar, clasificar y priorizar a tiempo real la información. Todo este funcionamiento asienta un entorno de altísima competitividad en el que la visibilidad es un factor completamente demandado, escaso y esencial para que los vendedores logren atraer posibles clientes y generar ventas (Einav, Farronato & Levin, 2016).

Es la publicidad un factor esencial dentro de los Marketplace y el motivo por el que resulta tan interesante tomar esta línea de trabajo. Es un área que cada vez está adquiriendo más dinamismo y crecimiento. Así se presenta en un informe de eMarketer el cual se orienta a la inversión en el *retail media* en EE. UU. y que proyecta que esta inversión crecerá aproximadamente de 58,79 mil millones de dólares en 2025 a unos 69,33 mil millones en el 2026. La gran concentración de todo ese dinero está absorbida por dos grandes: Amazon Ads que cuenta con una cuota del 79,7% y Walmart Connect con una del 8%, evidenciando una clara bifurcación de mercado (Willens, 2025).

Asimismo, la democratización del acceso al mercado digital permitido por estas plataformas constituye un factor determinante que también justifica el presente análisis. Este modelo publicitario puede llegar a estar al alcance de todo tipo de agentes, desde el emprendedor con un presupuesto muy limitado, hasta las marcas más grandes. Esto es uno de los principales atractivos, todo el mundo puede acceder a millones de clientes a nivel global.

En este contexto, la publicidad interna ha adquirido un papel primordial. Lejos de lo que se conoce como publicidad tradicional, los anuncios que se usan en los Marketplace son mucho más relevantes y tienen mayor potencial de conversión debido a que están integrados dentro de los procesos de búsqueda y compra. Esto también conlleva una toma de decisiones altamente rápida y precisa sobre qué anuncio mostrar, a quién mostrárselo, con qué puja hacerlo, cuándo... Para resolver esta complejidad se usa el Machine Learning, el cual ofrece un análisis de grandes volúmenes de datos y la predicción de posibles comportamientos futuros, entre otras cosas, en tan solo milésimas de segundo (Yang et al., 2022).

Toda la cadena de procesamiento del Machine Learning aplicada a la publicidad de Marketplaces supone un proceso muy complejo en el cual toman acción varias formas de aprendizaje y fases, cruciales para que se desarrolle de la mejor forma posible. Todos estos mecanismos mejoran la eficiencia publicitaria y la estructura competitiva Marketplace, beneficiando simultáneamente al consumidor (Cai et al., 2017).

Pese a que el volumen de literatura técnica sobre los modelos y fases que componen la cadena de procesamiento está creciendo, hay falta de información en el análisis de sus implicaciones competitivas. La mayoría de los estudios no cuestiona si el acceso real a ese sistema es homogéneo o no entre los distintos actores que están compitiendo. Y por lo tanto tampoco tratan qué consecuencias puede llegar a tener si existiera esa asimetría en la estructura competitiva del mercado. Este trabajo pretende contribuir a cubrir esa laguna. Por ello se analizará la cadena de procesamiento tanto como un sistema técnico de procesamiento de datos, como un mecanismo con un acceso diferencial entre actores que genera y sostiene ventajas competitivas estructurales dentro del ecosistema de los Marketplaces B2C.

1.4 Estructura del trabajo

Este Trabajo de Fin de Grado está estructurado de tal forma que sea un análisis que vaya avanzando desde lo más general, hasta un estudio en detalle de todas las fases que toman lugar en el proceso de Machine Learning aplicado a la publicidad automatizada en Marketplace B2C.

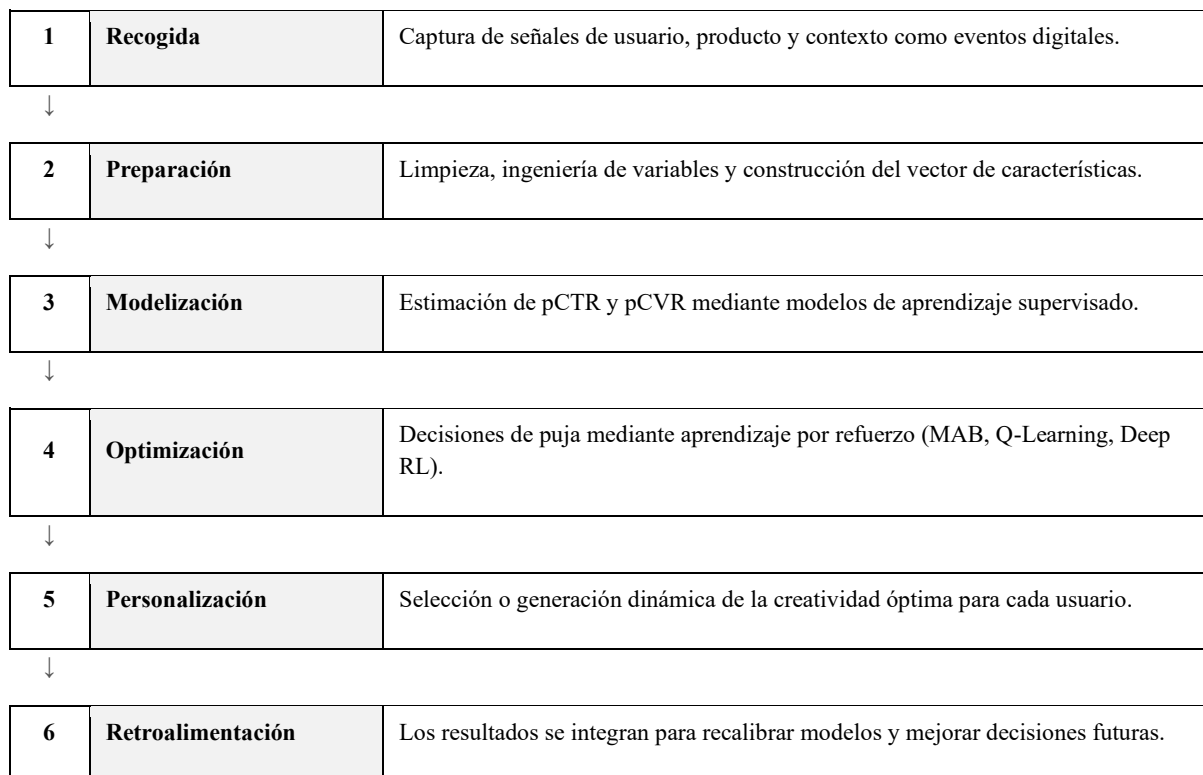
Tras un primer capítulo introductorio, el segundo capítulo establece las bases técnicas y conceptuales necesarias: qué son los Marketplace, en qué consiste el funcionamiento de la publicidad y automatización en estos, cómo es la competitividad o distintas métricas usadas para las evaluaciones de rendimiento. A continuación, el tercer capítulo profundiza en el papel central de la información en la automatización, abordando tipos de datos y señales, calidad de los datos y el ruido y sesgos, cómo condiciona todo esto el rendimiento.

El núcleo de todo estará en los capítulos del 4 al 9, dedicados de forma individual a las seis fases de la cadena de procesamiento previamente descritas, con un enfoque analítico y aplicado. El capítulo 10 propone un marco de análisis propio que sintetiza las seis barreras estructurales identificadas como sistema encadenado, analiza por qué son estructurales y no temporales, y desarrolla el concepto de espectro de apropiación

diferencial como respuesta a la pregunta central del trabajo. El capítulo 11 recoge las conclusiones, los hallazgos más relevantes y las limitaciones del estudio.

Figura 1

El pipeline de Machine Learning como ciclo de mejora continua



Los resultados de la fase 6 reinician el ciclo retroalimentando la fase 1

Nota. Elaboración propia. La fase de retroalimentación cierra el ciclo conectando los resultados de cada campaña con la fase de recogida, convirtiendo el pipeline en un sistema de aprendizaje acumulativo.

CAPÍTULO 2. BASES DE LA PUBLICIDAD EN MARKETPLACES B2C

2.1 Qué es un Marketplace y sus tipos

Un Marketplace se define como una plataforma en internet que conecta vendedores y compradores. Se puede entender como un inmenso centro comercial online en el que hay multitud de tiendas y de clientes interactuando en un mismo entorno. La plataforma actúa como intermediario, facilitando y optimizando el espacio de encuentro, los pagos, la logística y la confianza entre partes (Hagiu & Wright, 2015). Este soporte integrado y cerrado de compraventa es fundamental para entender el crecimiento de los Marketplace en el comercio electrónico global, y estudiaremos el porqué más adelante.

Para entender cómo funcionan los Marketplace, es clave establecer cómo se clasifican y determinar qué tipología interesa más para el estudio de la publicidad automatizada. Se pueden clasificar de varias maneras, aunque este análisis se centrará en las tres tipologías más comunes: según su alcance de catálogo, según la naturaleza de la oferta y según los participantes.

En primer lugar, hay que atender a la clasificación según su alcance de catálogo, donde se distinguen los Marketplace generalistas y los especializados. Por un lado, los generalistas, como bien indica su nombre, ofrecen una carta de innumerables productos como por ejemplo Amazon. Por otro lado, los especializados ofrecen un catálogo mucho más limitado, pero dando gran profundidad a esa categoría para un nicho en especial, como ocurre con Zalando en el sector de moda. Una segunda forma es por la naturaleza de la oferta, ya que pueden ofrecer productos o servicios, existiendo también modelos híbridos que ofrecen ambos tipos. Aquellos que ofrecen productos son más conocidos, por ejemplo, AliExpress, pero un ejemplo curioso de aquellos que ofrecen servicios es TaskRabbit orientada a contratar servicios locales y tareas domésticas. Una tercera forma de categorizarlos es según los participantes y el modelo de negocio base. En la mayoría de los Marketplace más populares el vendedor vende a un consumidor final, lo que se denomina B2C. Los B2B son otra variante que se caracteriza por hacer transacciones entre fabricantes y comercios. Por último, están los C2C, en los que son los propios particulares los que intercambian bienes y servicios, siendo la imposición de la confianza y convivencia clave para lograr que se negocie entre desconocidos (Einav et al., 2016; Grewal et al., 2017).

El modelo de Marketplace que destaca como el más relevante y representativo para estudiar la publicidad automatizada es el B2C. Esto se debe a como combina al mismo tiempo tres características: alta competencia, alta intención de compra de los usuarios y la gran capacidad de medición. Características que explican por qué la publicidad automatizada en los Marketplace B2C ha alcanzado un alto grado de madurez. Todas estas cualidades se irán desarrollando posteriormente (Einav et al., 2016; Grewal et al., 2017).

2.2 El Marketplace como entorno publicitario cerrado

Los Marketplaces B2C funcionan como un ecosistema digital controlado de forma íntegra por la propia plataforma. Espacio en el que se concentran e interaccionan la oferta de los vendedores, la demanda de los consumidores y la gestión de los anuncios,

formando lo que se denomina un entorno publicitario cerrado. Encontramos varios ejemplos dentro de estos como son Amazon, Alibaba etc.

Los Marketplace actúan como soporte publicitario y gestor de inventario de anuncios simultáneamente, a diferencia de las webs abiertas cuyo soporte y red publicitaria suelen ser entidades diferentes. Esto permite tener lo que coloquialmente se denomina un Walled Garden, un control sobre la experiencia del usuario total. No dependen de redes publicitarias ajenas, sino que muestran publicidad integrada y nativa de una forma orgánica dentro de la propia web, apareciendo en el proceso de navegación y descubrimiento del producto. Este dato es muy interesante ya que permite mantener al consumidor dentro de un entorno de compra y reduce la dispersión de su atención hacia otras plataformas abiertas. Por ejemplo, Amazon con su sistema de Amazon Ads integra los anuncios en la propia interfaz de esta misma forma y no presenta publicidad externa que saque a otra web o que pueda llegar a percibirse intrusiva (Mabaya, s. f.).

La característica de publicidad cerrada trae consigo multitud de ventajas estratégicas para las partes interesadas, especialmente para la plataforma y los anunciantes. Lo primero a destacar es que un Marketplace dispone de datos propios, clave a la hora de segmentar y orientar la publicidad con gran precisión. Dependiendo del perfil del comprador y de todo su historial de datos, la plataforma elige mostrar un anuncio u otro. Además, por lo general, la audiencia de los Marketplace suelen ser usuarios que están en una etapa avanzada del proceso de compra. Están activos buscando productos y predispuestos a adquirir aquello que ofrece el anuncio clicado, lo que hace que las campañas de publicidad aquí tengan una tasa de conversión bastante elevada y por lo tanto sean muy interesantes y eficientes.

Si analizamos los datos más recientes se puede asegurar que la publicidad en los Marketplaces es una fuente de ingreso a gran magnitud y muy destacable. Un ejemplo lo podemos ver en Amazon cuyo negocio publicitario creció en 2024 con ingresos que alcanzaron la cifra de 56.200 millones de dólares, frente a unos 47.000 millones de dólares del año anterior, siendo el tercer mayor nombre en publicidad digital, por debajo tan solo de Google y Facebook (Mabaya, s. f.).

2.3 Bases de la publicidad automatizada: formatos, ubicaciones y objetivos en Marketplace B2C

Cómo hemos visto previamente, los Marketplace integran la publicidad en el proceso de compra de cada usuario, allá donde este está tomando las decisiones, donde está usando la plataforma de manera activa. Esta publicidad puede tomar distintos formatos, situados en ciertas ubicaciones y con varios objetivos principales, pero siempre velando por integrarse de la forma óptima en la experiencia de compra. De este modo, lo que se busca es aumentar la visibilidad y la conversión de aquello que se está publicitando, consiguiendo así el máximo rendimiento de la inversión. En este punto desarrollaremos las distintas tipologías de anuncios más relevantes y usados por las principales plataformas líderes, recogiendo especialmente el ejemplo de Amazon Ads y su amplia estructura publicitaria la cual ofrece diversas opciones a los vendedores (Amazon Ads, s. f.).

El formato principal en la publicidad cerrada es aquel que promueve listados de productos individuales, productos concretos. La principal ubicación es en los resultados después de realizar una búsqueda y en las páginas de producto. Amazon, por ejemplo, ofrece al vendedor dos herramientas principales, la posibilidad de orientar los anuncios con palabras clave y la posibilidad de segmentar por producto. Estas dos herramientas ayudan a establecer cuando el anuncio debe mostrarse y cuando no, cuando el contexto del usuario que está buscando es relevante. El objetivo principal es la conversión directa, desde una demanda que ya existe a un tipo de producto, y por lo tanto gran probabilidad de compra, atraer clics y conseguir anteponerse a la venta de los competidores que ofrecen algo muy similar. Esta es la oferta principal de plataformas como Aliexpress, que aún no termina de especializarse en las tipologías que veremos a continuación (Amazon Ads, s. f.).

En cambio, existen otros casos en los que la intención deja de ser promocionar un producto concreto y pasa a ser promocionar una marca. Esto es una herramienta idónea para dar a conocer y destacar la identidad de una marca, permitiendo mostrar un anuncio que incluya un logotipo, un mensaje y una selecta gama de productos, evidentemente estando el Store al que se guía dentro del propio Marketplace. Estos suelen tener ubicaciones algo más destacadas y con más visibilidad, suelen estar en la parte superior de la página de resultados de compra tras una búsqueda, lo primero que se ve tras realizar esta. El objetivo principal aquí no se limita tan solo la conversión inmediata de ventas,

sino que también se vela por que el reconocimiento sobre la marca de los usuarios crezca y consigan diferenciarse en categorías muy ofertadas frente a marcas que con una gama de productos y propuestas similares (Amazon Ads, s. f.).

Es completamente común y esperable que pese a conseguir captar la atención de los usuarios hacia tu producto o categoría de productos, el comprador no consiga convertir esas ventas. Es aquí donde es de gran utilidad el formato de Display el cual pretende impactar al usuario más allá de aparecer en el proceso de búsqueda de una palabra clave en ese momento. Son anuncios más gráficos como por ejemplo banners, imágenes grandes... que pueden llegar a aparecer incluso fuera del propio Marketplace. Esto se consigue a través de las redes de audiencia, agrupaciones de posibles compradores con tendencia a estar interesados en algo en común para facilitar una segmentación precisa. El objetivo principal es claro, aumentar cobertura y conseguir llamar la atención de posibles perfiles de interés, recuperar usuarios que, como se ha explicado antes, no ejecutaron la compra o, a los que sí lo hicieron, conseguir que la vuelvan a hacer y trabajar así en su fidelización (Amazon Ads, s. f.).

2.4 El proceso de asignación del espacio: subastas, pujas y el modelo CPC

El espacio visible dentro de un Marketplace para los anuncios no es ilimitado, y las posiciones de alta atención son escasas. Esto sumado a la gran cantidad de vendedores con interés a aparecer en las mismas búsquedas establece una necesidad de un sistema rápido, efectivo y justo. El mecanismo más habitual es una subasta automatizada a tiempo real. En fracciones de segundo el algoritmo asigna qué anuncios mostrar y en qué posición deben aparecer. (Edelman et al., 2007).

Estas pujas funcionan mediante un modelo denominado coste por clic o CPC. La clave de este modelo es que el anunciante no paga por aparecer, sino que paga en el momento en el que el usuario haga clic en el anuncio. Cada vendedor asigna cuál es su puja máxima por el clic en su anuncio, importante para determinar qué posición de visibilidad acaba consiguiendo (Amazon Ads, s. f.). El valor monetario de la puja no lo es todo, dentro de la subasta automatizada también influyen de manera determinante la calidad y relevancia esperada. Un caso en el que un anuncio sea poco relevante, pero por el que se ha pagado mucho, podría acabar degradando en gran medida la experiencia y satisfacción del comprador en el Marketplace. Google Ads por ejemplo tiene la herramienta denominada *Quality Score* que sirve para medir la utilidad y relevancia esperados que puede llegar a suponer el anuncio para el usuario (Edelman et al., 2007).

Por último, es fundamental para comprender la subasta de segundo precio generalizada. En este modelo, el anunciante que se establece en una posición no tiene por qué acabar pagando la cantidad máxima que ofreció. Por ejemplo, el ganador no suele pagar la puja máxima que ha impuesto, sino una cantidad ligeramente superior a la del segundo mejor postor. Mecanismo que incentiva a pujar de forma competitiva, puesto que el precio efectivo tiende a venir marcado por la presión de la competencia, no por el máximo declarado (Amazon Ads, 2025).

2.5 Métricas

Para cuantificar el rendimiento de las campañas publicitarias en los Marketplace B2C se utilizan varias métricas, con el fin de tener datos sobre los que tomar acción. Estas métricas ofrecen indicadores en todo el proceso de conversión del anuncio, desde la visibilidad inicial hasta la propia conversión de venta. Las métricas que abordaremos son las impresiones, la tasa de clics (CTR), la tasa de conversión (CVR), el coste por clic (CPC), el retorno de la inversión (ROAS) y la ratio de coste publicitario sobre ventas (ACoS) (Amazon Ads, s. f.; Google Ads, s. f.).

La primera métrica a desarrollar son las impresiones. Estas cuantifican cuántas veces se ha mostrado un anuncio a los usuarios en la plataforma, cada vez que carga en sus pantallas. Las impresiones lo que miden es la visibilidad que tienen las campañas publicitarias. Miden cuanta audiencia ha sido expuesta al anuncio, pero no si el usuario interactuó con este. Esta métrica sirve más como base de las siguientes.

Por otro lado, encontramos las tasas de clics, o CTR. Antes hemos hablado de las impresiones, el CTR indica qué porcentaje de estas impresiones se han convertido en clic. Lo que refleja es el atractivo o la relevancia que supone un anuncio para la audiencia. Por lo que un CTR alto significará que el anuncio es pertinente y llamativo, un CTR bajo puede indicar que no se ha conseguido capturar la suficiente atención del público objetivo. Su cálculo es tan sencillo como $CTR = (\text{n}^\circ \text{ de clics} \div \text{n}^\circ \text{ de impresiones}) \times 100$. Por ejemplo, si una campaña ha tenido 5000 impresiones y 100 clics, el CTR será del 2%. Pese a todo esto, la investigación en publicidad digital advierte de no sobredimensionar esta métrica, que se deben mirar otros datos. El clic es solo una forma de respuesta, pero también puede haber efectos de recuerdo o consideración, que aumentan la probabilidad de clic a futuro y los cuales no se pueden capturar (Chandon, Chtourou & Fortin, 2003).

La tercera métrica por tratar es la tasa de conversión o CVR. Esta mide el porcentaje de usuarios que, tras haber clicado, ejecutan la acción deseada, realizan una conversión. En los Marketplace lo más común es que esta acción objetivo sea que el usuario realice una compra (Amazon Ads, s. f.; Google Ads, s. f.). Lo que realmente está indicando la tasa de conversión es como de persuasivo y coherente es el anuncio. Un CVR alto va a denotar que la coherencia entre el anuncio, la oferta de valor del producto y la expectativa del comprador (Chandon et al., 2003). Por el contrario, si es bajo y pocos acaban ejecutando la acción esperada, podrá ser por una falta de correspondencia entre lo que se prometía y lo que la página acaba ofreciendo. Que el usuario no encuentre lo que esperaba, al precio que esperaba o con la valorización de los demás usuarios esperada. Un ejercicio interesante es estudiar la combinación entre CTR y CVR. Un CTR alto y un CVR bajo puede ser muy alarmante, gran cantidad de usuarios dan clic y muy pocos acaban en conversión, poniendo en duda la coherencia entre lo anunciado y lo ofertado. Un CTR bajo, pero un CVR alto indica que, aunque no se atraiga tanto usuario, aquellos que lo clican sí que están muy interesados o cualificados en obtener lo ofrecido (Yang et al., 2022).

A continuación, el coste por clic o CPC va más enfocada a medir el costo. Lo que evalúa es la eficiencia del gasto promedio que se hace al pagar por cada clic. Un CPC alto puede indicar que se existe una competencia elevada o que se han elegido palabras clave de mucho costo. En cambio, uno bajo lo que puede indicar es que estás compitiendo en un nicho mucho más económico. En líneas generales, es una métrica clave que refleja el costo del tráfico que estás generando hacia tu página web y refleja también la eficiencia económica que acaba teniendo una campaña (Google Ads Help, s. f.-b).

Definamos también la métrica de ratio de coste publicitario sobre ventas o ACoS. Esta evalúa la eficiencia de una campaña en cuánto a las ventas finales generadas respecto al gasto publicitario realizado. Un ACoS alto significa que gran parte de los ingresos que está generando el producto, están consumiéndose en el coste de la publicidad. Por otro lado, una ratio de coste publicitario bajo muestra gran eficiencia puesto que el coste publicitario está siendo moderado en relación con el número de ventas generado (Amazon Ads, s. f.-i).

Por último, también cabe mencionar el retorno de la inversión o ROAS. Este es básicamente la métrica desde la perspectiva opuesta al ACoS puesto que mide el retorno de la inversión publicitaria. No se suele mostrar como porcentaje, sino que cuando se

habla de retorno de inversión se analiza como los x ingresos obtenidos por cada x invertido en anuncios. Por ejemplo, una campaña que haya dado 5\$ de ingreso por cada 1\$ invertido, representa un ROAS de 5,0. Por lo que un retorno de inversión superior a uno ya quiere decir que el retorno supera lo invertido. Un ROAS igual a 1 indica que la campaña está en un punto de equilibrio bruto. Y por último un ROAS menor a 1 representaría que no se está llegando ni a recuperar el dinero invertido (Moon et al., 2022).

Es el análisis en conjunto de todas estas métricas lo que permite entender al vendedor de una mejor manera como de efectivas están siendo sus campañas, desde multitud de aspectos. Y con esto, optimizar lo que está ofreciendo y alcanzar la atención y conversión de su público objetivo de la manera más eficiente.

2.6 Por qué se automatiza

La automatización en la publicidad ha surgido debido a la complejidad y escala que ha ido adquiriendo a lo largo de los años. Los volúmenes masivos de datos que conllevan las distintas tareas requieren sistemas de aprendizaje en gran escala, cuya optimización de rendimiento reside en ajustar el modelo y decisiones en todo momento. Esto ha hecho que vendedores y plataformas se vean obligadas a apoyarse en algoritmos y técnicas de Machine Learning, siendo imposible la gestión total manual (McMahan et al., 2013).

Por ejemplo, desde el punto de vista del vendedor, es evidente que es imposible que la gestión de los cientos de productos y términos relevantes con las que tratan sea eficiente si no hay una automatización de por medio. Con esta, la carga de operar con campañas se reduce drásticamente y da rapidez a todo el proceso. Hay multitud de opciones que ayudan e incentivan a que los vendedores usen las plataformas. Por ejemplo, Amazon con el *automatic targeting* ofrece al vendedor una forma automática en la que mostrar su anuncio, decidiendo la plataforma en qué búsquedas y productos mostrarlo. En lugar de que sea el anunciante el que lo decide todo manualmente. No solo agiliza el proceso, sino que también sirve para descubrir términos útiles a futuro. Otro ejemplo son las pujas dinámicas, dónde Amazon es el que ajusta automáticamente la puja dependiendo de la conversión que el algoritmo considere que va a tener (Amazon Ads, 2025).

Para la plataforma, la automatización cumple una función clave: resolver la asignación de posiciones de los anunciantes de una forma en la que se mantenga el equilibrio entre la relevancia que va a tener para los usuarios y los ingresos máximos

(Edelman et al., 2007). Para esto, se usan modelos capaces de estimar el valor de las impresiones y sistemas de decisión que se ejecutan teniendo en cuenta restricciones, como presupuestos y horizontes temporales, bajo las que se analiza la puja (Cai et al., 2017).

Las pujas a tiempo real son parte de un proceso secuencial y dinámico, en el que cada decisión influye en las futuras que se vayan a tomar. A través del sistema de aprendizaje, se analizan esos resultados y se incorporan al modelo para optimizar asignaciones en un futuro (Cai et al., 2017).

2.7 Las asimetrías estructurales de la cadena de procesamiento

A lo largo de toda la literatura sobre los Marketplaces B2C es muy frecuente encontrar el argumento sobre la democratización del acceso al mercado digital. Se expone como cualquier vendedor puede crear campañas publicitarias con una inversión mínima y teniendo acceso a grandes grupos de consumidores potenciales (Einav et al., 2016). Este argumento pese a ser formalmente correcto, conlleva una distinción muy relevante y la cual este trabajo considera fundamental: El acceso de un actor a la interfaz del sistema publicitario no quiere decir que este controle su arquitectura (Lambrecht & Tucker, 2015). Por ejemplo, cuando un vendedor crea su primera campaña en una aplicación como Amazon Ads, tiene acceso a la superficie de proceso la cadena de procesamiento, como a las subastas o a las métricas de rendimiento. Pero no tiene forma de determinar realmente su posición competitiva porque no controla ninguna de las fases del proceso. Todas las decisiones que toma la plataforma por él hacen que se impongan los datos, estrategias de puja y modelos de estimación que esta considere (Cecere et al., 2024). Por ello aparece la cuestión principal a tratar ¿Hasta qué nivel profundidad puede un actor apropiarse del sistema?

Este trabajo se apoya en el marco VRIO desarrollado por Barney (1991) para analizar esta cuestión de forma rigurosa. Barney (1991) expone en este marco que un recurso o capacidad constituye una fuente de ventaja competitiva sostenida cuando cumple cuatro condiciones de forma simultánea: ser valioso, ser escaso, ser difícil de imitar y estar respaldado por una organización que lo pueda explotar. Si analizamos los Marketplaces B2C líderes y todos los datos propios que tienen acumulados, vemos que cumplen los cuatro criterios de forma clara. A continuación, la Tabla 1 que lo recoge.

Tabla 1

Aplicación del marco VRIO a los datos propios de los Marketplaces líderes.

Criterio VRIO	Pregunta clave	Aplicación a los datos propios del Marketplace	Implicación
Valioso (V)	¿Permite explotar oportunidades o neutralizar amenazas?	Sí. Permiten predecir intención de compra con precisión creciente y orientar cada impresión al usuario más propenso a convertir.	Fuente de ventaja competitiva potencial.
Escaso (R)	¿Pocos competidores poseen el recurso?	Sí. Ningún actor externo accede al mismo volumen y granularidad de señales de comportamiento dentro de la plataforma.	Ventaja competitiva sobre actores externos.
Inimitable (I)	¿Es difícil de imitar o replicar?	Sí. Requiere años de interacciones de millones de usuarios. No puede replicarse con inversión puntual.	Ventaja competitiva sostenida en el tiempo.
Organización (O)	¿Está la empresa organizada para explotarlo?	Sí. Infraestructura de ML, equipos de <i>data science</i> y pipeline integrado aprovechan el recurso de forma sistemática.	Ventaja competitiva sostenida y explotada.

Nota. Elaboración propia a partir de Barney (1991).

El criterio de ser inimitable merece una atención particular. En el marco VRIO se identifican tres mecanismos para medir la dificultad de imitación de un recurso: la ambigüedad causal, la dependencia de la trayectoria histórica y la complejidad social. La ambigüedad causal hace referencia a la imposibilidad de identificar siempre con precisión qué combinación de las señales produce predicciones más acertadas. La dependencia de la trayectoria histórica implica que tras años de interacciones de millones de usuarios hay un enorme volumen y riqueza de datos acumulados. Por último, la complejidad social se debe a la combinación de millones de interacciones que se han ido registrando en un entorno de compra cerrado y controlado (Lambrecht & Tucker, 2015). Los datos de los Marketplaces líderes cumplen los tres mecanismos de forma simultánea, convirtiéndolos en un activo inimitable.

Para explicar la dinámica temporal y no limitar el estudio de la ventaja en un momento dado, este trabajo incorpora también el concepto de dependencia de la trayectoria formulado por Arthur (1989). En sistemas donde el aprendizaje depende de la experiencia acumulada, la posición inicial determina la futura, tiende a consolidarse y bloquearse. El concepto clave aplicado a la cadena de procesamiento publicitario explica que el mecanismo funciona de tal manera que aquel actor que empieza con más datos va a tender a generar predicciones de mayor precisión, que llevarán a más conversiones y por lo tanto más datos. Cada ciclo hace que esta ventaja se acentúe. Este mecanismo fue formalizado por Varian (2018) en su argumento de que los datos presentan rendimientos crecientes de escala en el aprendizaje. El valor predictivo del *dataset* mejora según se va acumulando la información. Es por todo esto por lo que la brecha entre los actores con más datos y los que tienen menos va a ampliarse con el tiempo.

La combinación de ser inimitable estructuralmente y tener un refuerzo acumulativo plantea la pregunta central de este trabajo ¿Hasta qué nivel de profundidad puede un actor posicionarse dentro del sistema? Responder a esa pregunta de forma sistemática, apoyándose en el análisis de cada fase desarrollado en los capítulos siguientes, es la contribución original que este trabajo propone.

CAPÍTULO 3. LA INFORMACIÓN COMO BASE DE LA AUTOMATIZACIÓN

La base de la automatización publicitaria en los Marketplaces B2C son las señales de comportamiento, producto y contexto dentro de un entorno controlado. Estas señales funcionan como variables para predecir resultados y guiar decisiones en la puja, segmentación y presupuesto. Son tanto la calidad como las restricciones las que delimitan cómo acaba funcionando el Machine Learning con estas señales.

3.1 Tipos de señales y datos

Los Marketplace B2C no necesitan datos externos para optimizar el rendimiento y predecir las intenciones de los usuarios. Son las señales las que actúan como materia prima y establecen toda la información necesaria. Las más relevantes a tratar se agrupan en: usuario, producto, contexto, campaña y competencia.

Las señales de usuario son las que capturan tanto intención como las preferencias. Encontramos variables como consultas de búsqueda, en qué ha hecho clic, tiempo de permanencia, repetición de visitas, contenido añadido al carrito, historial de compra...

Todo esto lo que hace es determinar si lo que se está buscando tiene una intención de compra elevada. Amazon Ads considera a las acciones de añadir a la cesta y comprar como las conversiones medibles y más relevantes a considerar en el análisis de intención (Amazon Ads, s. f.).

Las señales de producto describen lo que es el producto en sí, describen la oferta y su competitividad. Aquí son relevantes el precio, los atributos, las valoraciones, la disponibilidad, las condiciones de envío... Si la competitividad del producto es baja, aunque haya una intención de compra alta, va a haber poca probabilidad de conversión (Amazon Ads, s. f.).

Las señales de contexto describen el momento y el comportamiento que tiende a darse en este. La hora, el día, la ubicación, el tipo de dispositivo... El comportamiento de compra varía mucho dependiendo del contexto. Las guías establecen estándares de medición que recomiendan que los resultados han de interpretarse y analizarse como segmentos separados. Por ejemplo, debe analizarse diferenciando por tipo de dispositivo, consiguiendo interpretar de forma correcta y útil los resultados (IAB & MRC, 2024).

Las señales de campaña informan cómo decide competir el anunciante: el presupuesto con el que cuenta, cantidad de dispuesta a pagar, estrategias de automatización... Por ejemplo, el hecho de que el anunciante decida usar la estrategia de puja fija o puja dinámica es una información relevante y define bien cómo está compitiendo el anunciante (Amazon Ads, 2025).

Por último, las señales de competencia representan la presión competitiva presente en las subastas. Variables como la densidad de anunciantes, palabras clave demandadas, precio al que se está pujando... Las subastas a tiempo real los costes de las impresiones dependen mucho de esta situación competitiva de la subasta, alzándose mucho los precios en situaciones de alta presión (Cai et al., 2017).

3.2 Valor predictivo

El valor de las señales depende de cuánta información aporte en vista a predecir y anticipar la respuesta de los usuarios. Hay tres propiedades que aumentan el valor: La intención, la recencia y la granularidad.

La intención es muy relevante. Todas las búsquedas mediante *keywords* y clics recientes van a dotar a una señal mucho valor de intención. Los usuarios transmiten

necesidad y limitan en gran medida el conjunto de posibles productos que están dispuestos a comprar (Google Ads, s. f.).

La importancia de la recencia radica en lo frecuentes que han sido determinadas preferencias de compra en un periodo temporalmente cercano, siendo estas normalmente más informativas que las históricas lejanas. Estas señales recientes están reflejando las ideas de usuario actuales. Por ejemplo, tiene mayor valor predictivo la búsqueda de unas zapatillas hace dos días que una compra que se realizó hace dos años. La clave es que la primera señala una intención activa, la segunda en cambio un evento puntual con escaso valor en la actualidad (Li & Kannan, 2014).

La tercera es la granularidad, la interacción entre señales. A nivel general, la combinación de variables de usuario, contexto o campaña suele tener mejor rendimiento predictivo. En Machine Learning se denomina vector de características a este listado de variables combinadas. Se usa el vector para estimar por ejemplo probabilidades de clic (pCTR) o de conversión (pCVR) (Cai et al., 2017)

3.3 Limitaciones y retos del dato

Como se ha desarrollado con anterioridad, los datos son la principal fuente de información para que el modelo pueda aprender y automatizar. Por lo que la calidad de estos datos tiene un gran peso. Se destacan a continuación los principales problemas más destacados en la calidad de los datos: El ruido y la medición imperfecta, los datos faltantes y estructurales, y los sesgos estructurales del dato

El primer problema son el ruido y la medición imperfecta. Impresiones de usuarios las cuales aparecen como tal en los datos, pero las cuales no significan nada puesto que el usuario realmente no vio el anuncio. Por ejemplo, cuando el anuncio queda fuera de la pantalla o simplemente cuando el usuario está navegando rápido y no se detiene a verlo. Por eso se han establecido criterios para determinar si las impresiones son servidas o visibles. La impresión servida son las cuales cargan, pero el usuario no llega a ver, y las visibles las que sí que ve. Para considerarse visto por el usuario, la IAB y el MRC (Media Rating Council) ha establecido un mínimo de 50% pixeles visibles durante 1 segundo en fotos, y 2 segundos en vídeos (IAB & MRC, 2024).

En segundo lugar, los datos faltantes y estructurales. Parte del tráfico puede ser no humano, por ejemplo, bots o spiders, y lo que hacen es distorsionar el aprendizaje y la interpretación económica. Este tráfico no humano y no legítimo es definido por el MRC

como “tráfico invalido”. Por su parte. La IAB distingue entre el tráfico no humano en GIVT: lo que es detectable más sencillamente mediante filtrados rutinarios, y SIVT: lo que es mucho más complejo de detectar y requiere una analítica avanzada (IAB Europe, 2021).

Por último, los sesgos estructurales de dato. En los sistemas de ranking y publicidad, la información observada está muy condicionada por lo que la plataforma decidió mostrar. Es aquí donde entra la posibilidad de que un producto que realmente sí que puede interesar, al no exponerse se considera como si no fuese irrelevante para los usuarios, esto se denomina sesgo de exposición. El sesgo de posición explica como los ítems que se posicionan en las ubicaciones superiores, reciben más clics y parecen mejores cuando no tienen la necesidad de serlo. También tiene importancia el sesgo de popularidad, que surge porque los productos que tienen más visualizaciones, muchas ventas o muchas reseñas, el sistema tiende a enseñarlos más. Esto lo que hace es que se entre en un círculo en el cual nuevos productos o nichos con menos visibilidad sean percibidos como menos relevantes por la plataforma (Klimashevskaja et al., 2024; Chaney et al., 2018).

CAPÍTULO 4. FASE 1: FASE DE RECOGIDA

Hasta ahora, se ha contextualizado la publicidad automatizada dentro de los Marketplace B2C. A partir de este capítulo, se pondrá el enfoque en las fases que componen todo el proceso.

La primera fase es la fase de recogida, en la que se captura el comportamiento de los usuarios como eventos, para construir las señales vistas en el capítulo anterior. Se abordará el cómo se capturan las señales, cómo se transportan y cómo se transforman. Esta fase es crucial, puesto que gran parte del código de los sistemas de Machine Learning reside en la infraestructura, especialmente en las capas de ingesta y transformación de datos.

4.1 Mecanismos de captura

Todas las acciones de los usuarios son registradas como eventos. Los eventos son las unidades mínimas de información dentro del sistema de recogida, estableciendo el quién, qué, cuándo y dónde en base a identificadores, marcas temporales y metadatos.

Esta transformación del comportamiento del usuario a eventos se lleva a cabo mediante varios mecanismos (Provost & Fawcett, 2013).

El primer mecanismo que tratar es el de píxel de seguimiento. Consiste en usar imagen de tan solo un píxel que sea invisible para el usuario. Cuando se carga la página desde el navegador, se manda una petición al servidor donde está la URL para poder cargar la imagen. Es en este paso donde se registra la información y de ahí se articula un evento (Amazon Ads, s.f.). Aquí se depende mucho del navegador del cliente y hay ciertas limitaciones puesto que hay multitud de bloqueos de privacidad.

Por otro lado, están los registros de eventos, los cuales se generan directamente desde los propios servidores cuando hay interacciones con el sistema. Ya no hay dependencia alguna del servidor externo, por eso son mucho más fiables. La información que recoge son por ejemplo los clics, las impresiones o consultas. Es aquí, y como ya se estableció en capítulos anteriores, donde se recoge la materia prima necesaria para la predicción (He et al., 2014; McMahan et al., 2013).

También hay que destacar el mecanismo de las cookies, el cual sirve para identificar al usuario dentro de un dominio o asociados. Se dividen en cookies de primera parte, las cuales se establecen en el dominio que se está visitando directamente, y las de tercera parte, donde distintos sitios cruzan datos para una construcción más rica de perfil de usuario. Este segundo tipo se encuentra ya en una fase de desaparición bastante avanzada por parte de los navegadores, lo que ha supuesto una revolución en el proceso de identificación de usuarios (Google, 2024). Es aquí donde los Marketplaces B2C tienen la ventaja competitiva de que siempre operan con datos recogidos desde su plataforma.

Por último, también es importante destacar el caso de las aplicaciones móviles. Es aquí donde nace lo que se denomina Kit de Desarrollo, o SDK, y se integran en las aplicaciones capturando eventos de forma nativa. También tienen ciertas limitaciones debido a las restricciones de privacidad establecidas por Apple después de que desarrollaran un sistema en el que el usuario debe consentir explícitamente el rastreo entre aplicaciones mediante el sistema ATT (Apple, 2021).

4.2 Infraestructura y desafíos operativos

Cuando se capturan los eventos, antes de que los modelos puedan usarlos, tienen que ser procesados. Hay dos tipos de procesamiento, un primer tipo en el que se agrupan los datos por temporalidad, más idóneo para entrenar a los modelos periódicamente. Y un

segundo en el que se procesan los eventos en el instante, destinado a acciones que requieren esta rapidez, como las pujas a tiempo real. Para este último existen herramientas como Apache Kafka o Amazon Kinesis, las cuales trabajan con flujos masivos de eventos con un retraso mínimo, disponiendo información a prácticamente en tiempo real (Zaharia et al., 2016; Kreps et al., 2011).

Dentro de la infraestructura durante esta fase, encontramos dos retos muy documentados: La retroalimentación retardada y la fragmentación entre dispositivos. La retroalimentación retardada aparece cuando transcurre un intervalo de tiempo elevado, horas o incluso días, entre el momento en el que aparece la impresión de un usuario y el momento en el que se acaba dando el resultado de conversión o no. Este desfase puede desajustar el modelo y provocar estimaciones erróneas (Ktena et al., 2019).

El segundo reto es la fragmentación entre dispositivos supone que un usuario está generando señales desde varios dispositivos, sin un mecanismo para relacionarlos, provocando que el sistema lo trate como usuarios independientes. Con esto se pierde información muy relevante para desarrollar un perfil de comportamiento completo. La solución en plataformas como los Marketplace B2C ha sido establecer un sistema de inicio de sesión determinístico el cual permita que el usuario se identifique en sus distintos dispositivos como uno solo (Provost & Fawcett, 2013).

Tabla 2

Los cuatro mecanismos de captura de eventos en sistemas de publicidad automatizada

Píxel de seguimiento	Registros de eventos	Cookies	SDK móvil
Imagen invisible de 1px cuya carga genera una petición HTTP que registra información del usuario y el contexto.	Generados directamente por el servidor al producirse una interacción: clics, impresiones, consultas de búsqueda.	Identifican al usuario dentro de un dominio (1ª parte) o entre distintos sitios (3ª parte) para construir perfiles de comportamiento.	Integrados en aplicaciones móviles, capturan eventos de forma nativa: aperturas, vistas de producto, tiempo de sesión.
<i>Vulnerable a bloqueadores de anuncios y restricciones de privacidad del navegador.</i>	<i>Alta fiabilidad. No depende del navegador del cliente.</i>	<i>Las cookies de 3ª parte están siendo eliminadas por los navegadores (Google, 2024).</i>	<i>Restringido por el sistema ATT de Apple desde iOS 14.5 (Apple, 2021).</i>

Nota. Elaboración propia a partir de Provost y Fawcett (2013), Amazon Ads (s. f.), He et al. (2014), Google (2024) y Apple (2021). Los registros de eventos son el mecanismo más fiable por no depender del navegador del cliente. Las cookies de tercera parte están en proceso de eliminación progresiva por los principales navegadores.

4.3 Implicaciones competitivas de la fase

La fase de recogida condiciona de forma irreversible todas las fases posteriores. Dentro de los ecosistemas Marketplace todos los actores generan señales, la diferencia está en acceder a métricas agregadas al rendimiento y controlar las señales que alimentan a los modelos predictivos. El conocimiento del vendedor se limita a saber cuántos clics tuvo; la plataforma a saber quién, por qué, dónde... La distinción entre los vendedores se basa en hasta qué punto pueden complementar esta dependencia con datos externos. La fase de recogida establece entonces la primera barrera estructural, la barrera de granularidad. Esta es universal entre los vendedores, lo que va a diferenciarlos competitivamente es esa capacidad de complementar datos propios externos (Provost & Fawcett, 2013).

CAPÍTULO 5. FASE 2: PREPARACIÓN Y ESTRUCTURACIÓN DE DATOS

Tras la captura y transporte de los eventos de comportamiento durante la fase de la cadena de procesamiento tratada en el capítulo anterior, el sistema dispone en este momento de datos en bruto. Durante esta segunda fase se transforman estos datos en variables numéricas estructuradas y limpias que componen un *dataset* y que si pueden ser usadas para predecir. Este proceso de transformación, según la literatura, se denomina preparación de datos. Es una etapa compleja que absorbe mucho trabajo y horas dentro del aprendizaje automatizado (Domingos, 2012).

5.1 Limpieza y validación

El primer paso en la preparación de los datos es detectar y corregir imperfecciones e incoherencias que puedan existir. Los problemas más comunes son: los valores ausentes como por ejemplo productos nuevos sin historial. Los valores atípicos como distorsiones y picos puntuales en el tráfico. Y también son un problema los registros duplicados. A todo esto, se suma lo que se desarrolló en el tercer capítulo, el tráfico no humano e invalido el cual tiene que ser eliminado al completo para que no contaminen el modelo. Esta limpieza es un paso completamente obligatorio y necesario para que las estimaciones sean fiables (Chapelle et al., 2015).

5.2 Ingeniería de variables

Contando con unos datos validados, el proceso de ingeniería de variables transforma las señales brutas en representaciones numéricas que el algoritmo puede

entender y procesar. Dependiendo del tipo de variable se va a procesar de una forma u otra. Las variables categóricas, por ejemplo, el tipo de categoría o de dispositivo, se codifican de forma numérica. La técnica denominada *one-hot* sirve para aquellas con pocos niveles, convierte los valores en un vector binario: Ropa [1,0] y Hogar [0,1]. En cambio, el *embedding* sirve para variables con muchos valores las cuales no tiene sentido convertir en un vector, el modelo aprende cual es la mejor representación y la más compacta en estos casos. Las variables continuas, por ejemplo, el precio o la puja, se normalizan, se llevan todas a una misma escala, y así no hay distorsiones ni malinterpretaciones. Por último, también cabe destacar las variables derivadas, las cuales condensan información histórica, por ejemplo, la tasa de conversión de un anuncio los últimos 7 días. Esto dota de más información y por tanto mayor capacidad predictiva del modelo (He et al., 2014).

Tras todo este proceso se obtiene lo que se denomina como vector de características. Es una representación numérica compacta de toda la información que ha obtenido el sistema sobre el usuario, el anuncio y el contexto en el instante en el que tiene que tomar la decisión. Es básicamente la señal que reciben los modelos posteriores. Toda la ingeniería de variables que da como resultado a este vector, es lo que la literatura califica como la palanca de mejora más poderosa de todo el proceso, siendo clave la mejora en la selección de las variables de entrada (McMahan et al., 2013).

Figura 2

Construcción del vector de características: de la señal bruta a la predicción

Tipo de señal	Ejemplos de señales brutas	Transformación
Usuario	Historial de búsquedas, clics, compras previas, tiempo de sesión.	→ <i>variable numérica</i>
Producto	Precio relativo, valoración media, categoría, disponibilidad.	→ <i>variable numérica</i>
Contexto	Hora del día, dispositivo, ubicación, estacionalidad.	→ <i>variable numérica</i>
Campaña	Puja máxima, estrategia de targeting, presupuesto restante.	→ <i>variable numérica</i>



VECTOR DE CARACTERÍSTICAS

$[x_1, x_2, x_3, \dots, x_n]$ - representación numérica compacta del triplete usuario - anuncio - contexto



MODELO PREDICTIVO

Estimación de $pCTR$ y $pCVR$ → valor esperado de la impresión → decisión de puja

Nota. Elaboración propia a partir de He et al. (2014) y McMahan et al. (2013). El vector de características es el único input que recibe el modelo predictivo: toda la información disponible sobre el triplete usuario - anuncio - contexto queda condensada en un array numérico que determina la estimación de $pCTR$ y $pCVR$.

5.3 Modelos no supervisados

Para entender esta fase también hace falta desarrollar las técnicas de aprendizaje no supervisado. El propósito de estas no es predecir, sino compactar la información. Destacan dos tipos, el *clustering* y la reducción de la dimensionalidad.

En el *clustering*, o clusterización en castellano, se utiliza el algoritmo *K-means*, el cual es fundamental en este proceso. Gracias a este se agrupan usuarios o productos de perfil de comportamiento similar. Se hace una distribución creando lo que se denominan clústeres, por ejemplo, el clúster de “compradores recurrentes de moda”. (Bishop, 2006). El hecho de pertenecer a determinado clúster es una variable más dentro del vector de características.

Por otro lado, está la reducción de dimensionalidad se utiliza cuando dentro de un vector de características con muchas variables, hay muchas de ellas que están relacionadas y aportan la misma información varias veces. Esto añade ruido y afecta negativamente al rendimiento. El Análisis de Componentes Principales combina esas variables correlacionadas, reduciendo el conjunto de componentes y aportando mayor variación informativa y con componentes no correlacionados (Géron, 2019).

5.4 Modelos supervisados

Estos modelos se van a utilizar en esta fase para estimar valores ausentes en el *dataset* a partir de categorías conocidas de entidades similares. Destacan especialmente: las técnicas de regresión lineal, la cual estima valores a partir de relaciones proporcionales entre variables. Los k -vecinos más próximos, que infieren valores promediando similares históricos. O los árboles de decisión los cuales establecen reglas de condición organizadas en forma de árbol y que capturan relaciones no lineales.

El caso que mejor explica la importancia de estos modelos supervisados es el denominado arranque en frío. Una primera campaña, un producto recién introducido o un usuario nuevo no tienen información de comportamiento. Es aquí donde la estimación de los valores ausentes en base a categorías desconocidas toma lugar y sirve hasta que se acumule un historial propio suficientemente extenso (Schein et al., 2002).

5.5 Implicaciones competitivas de la fase

La fase de preparación introduce una barrera de capacidad técnica para transformar el dato. Para la construcción de variables predictivas útiles se requiere talento especializado y un volumen de datos extenso para que estas variables sean fiables. El problema de arranque en frío presentado con anterioridad es un perfecto ejemplo. Sin historial propio, las estimaciones a partir de datos globales no van a ser tan precisas (Schein et al., 2002). Podemos comprobar como la fase anterior tiene entonces un gran impacto en esta, estableciendo una segunda barrera de capacidad técnica y volumen. Una señal menos rica producirá un vector de características menos preciso, aquí es donde se diferenciarán los actores. Se estudiarán las implicaciones en profundidad en el capítulo décimo.

CAPÍTULO 6. FASE 3: MODELIZACIÓN PREDICTIVA

En el momento en el que se obtiene el vector de características, el sistema dispone de una representación numérica estructurada para cada situación de decisión. Esta tercera fase, recibe el vector numérico para producir una estimación de probabilidad del comportamiento del usuario. Es por ello por lo que la fase de modelización predictiva es el núcleo del sistema de publicidad automatizada.

6.1 Problema de predicción: pCTR, pCVR y sesgo de selección

Las dos principales variables objetivo son la probabilidad estimada de clic (pCTR) y la probabilidad estimada de conversión (pCVR). El modelo va a estimar las probabilidades asignando un valor entre el 0 y el 1. Es el producto de ambas estimaciones lo que aproxima el valor esperado de la impresión. Este valor es lo que la plataforma utiliza para determinar el orden de los anunciantes dentro de la subasta. Es por ello por lo que un anuncio con un pCVR y un pCTR altos va a generar más valor esperado y obtendrá mejor posición en la subasta (Yang et al., 2022).

6.2 Evolución de modelos: tres generaciones

Los modelos de predicción de CTR y CVR han ido evolucionando a lo largo del tiempo conforme la disponibilidad de los datos y las capacidades computacionales aumentaban. Estudiar esta trayectoria y ver cómo se respondió a distintas limitaciones, resulta más revelador que explicar multitud de modelos actuales con pocas distinciones.

En la primera generación destacó especialmente la regresión logística. Es un modelo que fue adoptado de forma masiva debido a que es computacionalmente eficiente, escala bien con millones de variables y produce probabilidades que pueden interpretarse directamente. Richardson et al. (2007) fue uno de los primeros estudios que documentaron cómo formular, entrenar y evaluar un modelo predicción de clics, estableciendo las bases metodológicas. McMahan et al. (2013) analizaron el sistema de Google y expusieron como la plataforma implementaba regresión logística con miles de millones de parámetros, constituyendo un núcleo del sistema a nivel industrial. Sin embargo, la principal limitación que tiene es que asume relaciones lineales entre variables de entrada y resultado, no pudiendo capturar interacciones entre variables de forma automática. Por ejemplo, no sería capaz de capturar que el impacto del precio sobre la conversión varía según la categoría sí que un ingeniero la diseñe explícitamente para eso.

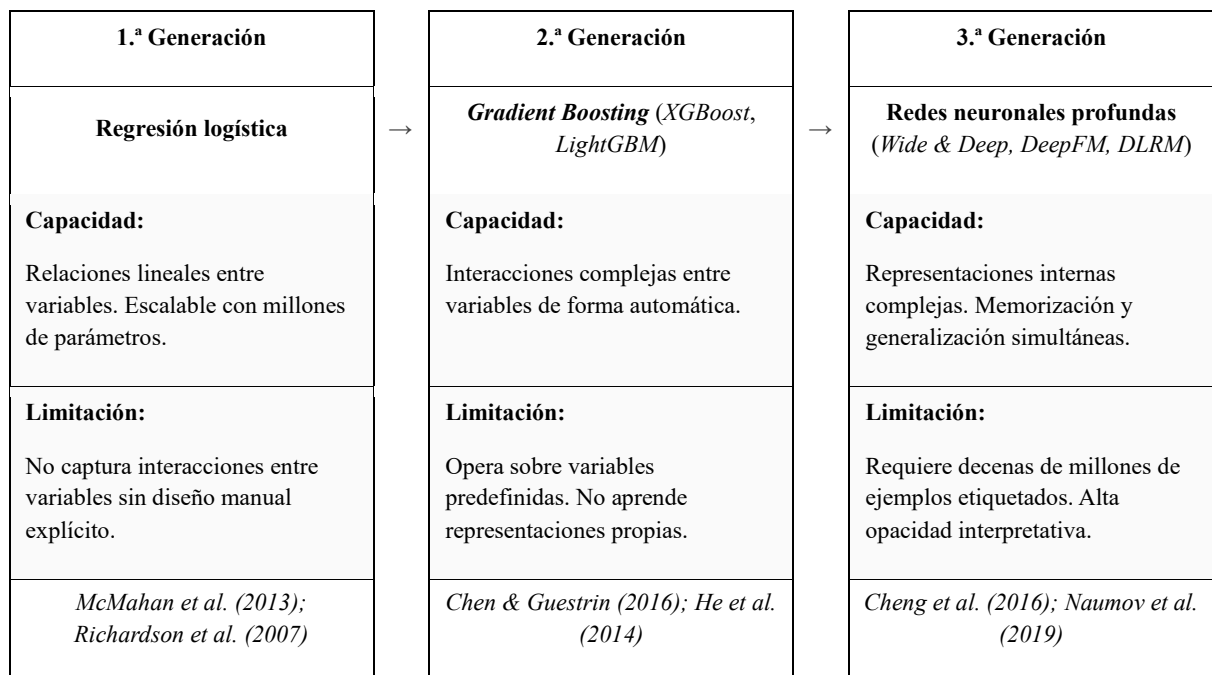
En la segunda generación tuvieron mucho peso los modelos de ensamblado, especialmente el *Gradient Boosting* en sus implementaciones *XGBoost* (Chen & Guestrin, 2016) y *LightGBM* (Ke et al., 2017). Estos modelos consisten en la combinación secuencial de árboles de decisión en la que cada árbol corrige los errores del anterior. Estos capturaban interacciones entre variables complejas de forma automática, cosa que no hacían los modelos de regresión logística. Facebook utilizó un sistema híbrido combinado los modelos de la primera y segunda generación. Usaba árboles de decisión para obtener variables más complejas, para luego meter estas en el modelo logístico, consiguiendo combinar lo mejor de ambas generaciones (He et al., 2014).

La tercera tiene como pilar a las redes neuronales profundas, el modelo con más capacidad para capturar relaciones no lineales complejas. Estos modelos aprenden de sus propias representaciones internas de los datos. Expone al vector a varias capas de transformaciones matemáticas para extraer patrones de gran complejidad. Se adaptó el modelo en la publicidad a partir de la década de 2010. Entre las arquitecturas más influyentes destacan tres las cuales son grandes referencias. *Wide & Deep* propuesta en Google Play, combina dos componentes: el lineal que memoriza las reglas frecuentes y el

profundo que generaliza a partir de combinaciones de variables. Ambas se entrenan de forma conjunta y se complementan para dar solución al problema que tenían los modelos pasados para memorizar y generalizar simultáneamente (Cheng et al., 2016). Por otro lado, está la arquitectura denominada *DeepFM*, cuyo punto fuerte es la técnica denominada factorización. La factorización automatiza el aprendizaje de interacciones entre variables. Esto permite que el modelo aprenda solo que combinaciones son relevantes (Guo et al., 2017). En Meta, Naumov et al. Desarrollaron la tercera arquitectura: la DLRM. Esta soluciona la altísima cardinalidad en identificadores de usuario y producto mediante *embeddings* aprendidos, que como hemos visto antes son representaciones compactas de variables. Estas arquitecturas son la base de las plataformas hoy en día, necesitándose una gran complejidad computacional muy superior a las generaciones de antaño.

Figura 3

Evolución de los modelos de predicción de CTR y CVR: tres generaciones



Nota. Elaboración propia a partir de McMahan et al. (2013), Chen y Guestrin (2016), He et al. (2014), Cheng et al. (2016) y Naumov et al. (2019). Cada generación resuelve la limitación principal de la anterior, elevando simultáneamente el umbral mínimo de datos requerido.

6.3 Métricas de evaluación: por qué la precisión siempre engaña

Para evaluar el rendimiento de un modelo de predicción de clics se necesitan usar métricas adaptadas. La tasa de acierto puede ser muy engañosa, por ejemplo, en modelos que predicen los no clics, puesto que el porcentaje de acierto sería muy elevado pero

inútil. Por ello se establecen dos métricas importantes: la denominada AUC-ROC y el Log Loss. El AUC-ROC mide que el modelo asigne y ordene bien a los usuarios en función de sus probabilidades de clicar. El Log Loss penaliza en función de la confianza de predicción. Por ejemplo, va a ser más penalizado un modelo que asigna un 95% probabilidad de clic que aquel que asigna un 55%, cuando el evento acaba no ocurriendo.

Es importante destacar que en esta fase los modelos no toman decisiones, simplemente producen estimaciones de probabilidad las cuales no son suficientes aún para determinar qué anuncio mostrar ni a qué precio hacerlo. Estas estimaciones alimentan la fase siguiente para que esta actúe.

6.4 Implicaciones competitivas de la fase

En la fase de modelización se introduce una barrera de volumen de datos etiquetados. Cada generación de modelos ha ido estableciendo requisitos de forma exponencial, hasta el punto de llegar a unas arquitecturas que necesitan decenas de millones de impresiones, clics y conversiones para producir datos fiables (Naumov et al., 2019). Por lo tanto, la barrera no es estática, con los avances tecnológicos crece también el umbral mínimo de acceso, obligando a los anunciantes a crecer al ritmo de la frontera tecnológica. Un anunciante que no alcanza ese umbral se ve obligado a aceptar las estimaciones pCTR y pCVR que produce la plataforma con datos más genéricos, sin la posibilidad de poderlas ajustar a su contexto específico. Se establece así la barrera estructural de volumen de datos etiquetados, cuyas implicaciones entre actores se desarrollan en el capítulo décimo.

CAPÍTULO 7. FASE 4: OPTIMIZACIÓN Y TOMA DE DECISIONES

Las estimaciones pCTR y pCVR de la fase anterior son claves para actuar en las subastas, pero no suficientes. La pregunta operativa de cuánto pujar por una impresión en el momento, no se responde únicamente con la probabilidad de un usuario de clicar o comprar. El problema se basa en la toma de decisiones secuenciales bajo incertidumbre que maximicen un objetivo acumulado a lo largo del tiempo. Es aquí donde entra el paradigma de aprendizaje por refuerzo, diseñado para modelizar agentes los cuales aprenden a tomar decisiones óptimas interactuando con el entorno (Sutton & Barto, 2018).

7.1 El problema de la puja como decisión secuencial

El problema principal de las pujas es que son de naturaleza secuencial. Cada decisión de puja está afectada por lo decidido anteriormente y lo que queda por decidir. Esto es debido a que cada puja consume presupuesto y se generan resultados que aportan información nueva y útil. Si un agente puja siempre lo máximo, el presupuesto se terminaría muy rápido. En cambio, uno conservador dejaría escapar demasiadas oportunidades. Toda la gestión de esta tensión requiere una visión de conjunto que los modelos del capítulo previo no tienen, como por ejemplo saber el presupuesto o el tiempo restante de una campaña. Por ello existe la capa de aprendizaje por refuerzo, la cual consigue cubrir la limitación de las estimaciones predictivas (Cai et al., 2017).

Tabla 3

Comparación entre puja estática y puja con aprendizaje por refuerzo

	Puja estática	Puja con aprendizaje por refuerzo
Decisión de puja	Fija o ajustada manualmente por el anunciante.	Adaptada automáticamente por el agente en cada subasta.
Uso del presupuesto	Se distribuye de forma uniforme o según reglas predefinidas.	Se asigna dinámicamente priorizando subastas de mayor valor esperado.
Exploración	No existe. El sistema no prueba estrategias alternativas.	El agente explora activamente estrategias nuevas asumiendo un coste de oportunidad.
Aprendizaje	No hay aprendizaje. La estrategia no mejora con el tiempo.	El agente actualiza su política de puja tras cada subasta observando la recompensa obtenida.
Resultado acumulado	El rendimiento depende de la calidad del ajuste manual inicial.	El rendimiento mejora progresivamente a medida que el agente acumula experiencia.

Nota. Elaboración propia a partir de Cai et al. (2017) y Sutton y Barto (2018). La puja con aprendizaje por refuerzo requiere presupuesto experimental para la fase de exploración, lo que constituye la cuarta barrera estructural del pipeline.

7.2 Multi-Armed Bandits y aprendizaje por refuerzo profundo

El *Multi-Armed Bandits* o MAB es el marco de decisión más simple dentro del aprendizaje por refuerzo. El nombre viene por la imagen de un jugador ante varias máquinas tragaperras, tiene que maximizar las ganancias, pero no sabe cuál paga más. En

publicidad, las maquinas serían las distintas estrategias de puja, mientras que el clic o la conversión serían la recompensa que se intenta obtener. El dilema reside en si se debe explotar, manteniendo las apuestas a lo que mejor funciona hasta ahora, o explorar, buscando alternativas que mejoren lo que se tiene. Este marco tiene dos algoritmos concretos, el primero es el algoritmo *epsilon greedy* y el segundo el denominado UCB. Este propone que se explore de forma aleatoria, fijando la probabilidad, y explotando el resto del tiempo. La otra alternativa es el UCB, este prioriza las opciones sobre las que hay más incertidumbre acumulada, la escasez de información es lo que atrae a explorar. Estos algoritmos está demostrado que superan de manera consistente a pujar estáticamente, sobre todo cuando la información es variable (Zhao et al., 2025).

En los casos en los que el espacio de decisión supera la complejidad que son capaces de tratar los MAB, como varias campañas simultáneas o distintos segmentos de audiencia, se usa un marco más potente. Se utiliza el algoritmo *Q-Learning* para entrenar y hacer aprender a un agente, por ensayo y error, la acción de puja que conviene más en cada situación posible. Este agente va construyendo una tabla con las situaciones posibles y aprende de forma autónoma mediante la observación de las recompensas que va obteniendo a lo largo del tiempo. Cuando el número de situaciones posibles es demasiado grande para ser aprendido de forma tabular, el *Deep Reinforcement Learning* reemplaza esa tabla por una red neuronal que generaliza mediante el aprendizaje de patrones entre situaciones familiares. Este es el que sirve para la complejidad industrial de escala masiva con miles de variables simultáneas (Smith & Larsson, 2019).

7.3 Implicaciones competitivas de la fase

Esta cuarta fase de optimización introduce una barrera de presupuesto experimental. Incluso los marcos de decisión más simples como los MAB utilizan un aprendizaje por refuerzo que requiere una exploración activa de estrategias alternativas. Esta exploración obliga a asumir un coste de oportunidad que un actor con presupuesto reducido no puede absorber. Esta situación obliga al actor a limitarse a usar estrategias estáticas, renunciando al aprendizaje adaptativo que mejoraría su posición con el tiempo (Cai et al., 2017). Es una barrera activa, la restricción que impone se va retroalimentando puesto que al no poder explorar no puede aprender, y por ello no mejorará su tasa de conversión ni generará presupuesto para mejorar. Se establece así en la fase de optimización la cuarta de las barreras que toman acción en la estructura de la cadena de procesamiento, cuyas implicaciones entre actores se desarrollan en el capítulo décimo.

CAPÍTULO 8. FASE 5: PERSONALIZACIÓN Y CREATIVIDADES DINÁMICAS

Mientras que la fase anterior abordaba cuánto pujar y a quién mostrar el anuncio. Esta quinta fase responde a con qué mensaje se le puede impactar. La decisión creativa no es meramente estética, sino también económica. Cuánto más relevante es un anuncio para el usuario, más probabilidad va a haber de clic y se va a mejorar la estimación de pCTR. La personalización creativa no es un añadido opcional en el proceso, sino que es clave en la eficiencia y está muy integrada en él.

8.1 Selección dinámica y experimentación

El enfoque más tradicional para decidir qué versión de un anuncio funciona mejor es el *A/B testing*. Funciona creando dos variantes, entre ellas se divide el tráfico para comprobar cual es la ganadora. Simplemente se tiene que esperar a acumular suficientes observaciones. Es un método robusto, pero con una limitación bien marcada, el tráfico que consume la variante perdedora durante el periodo de experimentación. Esto va a generar un coste de oportunidad bastante elevado, especialmente en plataformas de millones de impresiones. Los algoritmos MAB vistos en el capítulo anterior aportan una solución a este problema. Reasignan el tráfico a tiempo real, con el experimento aún activo, a la variante que mejor está funcionando. Explota la variante ganadora, pero sigue buscando alternativas. El algoritmo no se usa aquí para ver cuánto pagar, sino qué mensaje mostrar cuando se ha ganado. Esa capacidad de adaptación a tiempo real ha conseguido mejorar sustancialmente las CTR respecto al A/B estático (Geng et al., 2021).

8.2 Modelos generativos

Los modelos más recientes son los generativos. Estos permiten construir y adaptar un anuncio en función del tipo de perfil de los usuarios y los contextos a los que está yendo dirigido. Este principio se materializa en las grandes plataformas. Por ejemplo, Amazon tiene una funcionalidad que permite adaptar la unión de los distintos elementos de un anuncio en función del perfil. Una personalización va a tener un impacto medible y significativo en la conversión, el estilo de mensaje publicitario afecta a los consumidores de manera diferencial (Huang y Liu, 2022)

8.3 Implicaciones competitivas de la fase

La personalización es accesible para cualquier vendedor y, por lo tanto, aporta a todos la capacidad de crear múltiples versiones de su anuncio usando distintos elementos. Pero esta accesibilidad resulta engañosa desde el punto de vista competitivo. Tanto los algoritmos MAB como los modelos generativos necesitan un tráfico mínimo por variable, un volumen de impresiones suficiente como para que las diferencias de rendimiento sean significativas. Sin ese volumen, los experimentos no van a funcionar, no habrá una variable claramente ganadora ni capacidad de mejora. La quinta barrera estructural es establecida entonces por la fase de personalización: la barrera de volumen tráfico mínimo, cuyas implicaciones se desarrollarán en el capítulo décimo.

CAPÍTULO 9. FASE 6: RETROALIMENTACIÓN Y APRENDIZAJE **CONTINUO**

Después de todo el trabajo de las fases previas, esta fase cierra el ciclo integrando todos los resultados que han ido dando las decisiones tomadas, con el fin de mejorar las decisiones de futuros procesos. Sin esta fase, la cadena de procesamiento sería un sistema que podría ejecutar decisiones, pero que no aprendería de ellas. Gracias a esta, se convierte en un sistema de mejora continuada, donde cada campaña en la que se está invirtiendo alimenta y optimiza la siguiente (Sculley et al., 2015).

9.1 Online y Batch learning

Para incorporar los resultados de las campañas se utilizan dos modelos. El primero es denominado *batch learning* reentrena el modelo de forma periódica mediante la agrupación de los datos en ventanas temporales. Es sencillo de implementar, el problema es que introduce un desfase entre el mercado y el modelo. El segundo modelo consigue solucionar esto mediante la actualización del modelo de forma continua, se denomina *online learning*. Conforme van llegando nuevos resultados, va habiendo actualizaciones con el fin de que haya una adaptación a tiempo real a cambios de comportamiento del usuario o del entorno. Está demostrado como los sistemas de predicción de CTR a gran escala son mucho más precisos gracias a la frecuencia de los *online learning* respecto a los *batch learning*.

9.2 Concept drift y recalibración

El comportamiento del consumidor es volátil, cambia dependiendo de la estación, tendencias u otros eventos externos. La diferencia de la distribución de datos en el momento presente respecto a la distribución que se entrenó en el modelo es descrita por el fenómeno denominado *Concept Drift* (Sculley et al., 2015). Un modelo necesita una recalibración periódica, un ajuste de los datos hacia el momento actual para seguir manteniendo una precisión predictiva con el transcurso del tiempo.

9.3 Implicaciones competitivas de la fase

La sexta y última barrera que se impone en todo este proceso determina cuánto aprendizaje se acumula o se pierde, la barrera de apropiación del aprendizaje. El vendedor va a aprender sobre su contexto, la plataforma sobre el comportamiento de todos los vendedores que están participando. La posición vuelve a ser fundamental, el aprendizaje va a beneficiar al mejor posicionado. Aquel vendedor con más historial tiende a detectar los errores más rápido. Esta barrera vuelve a amplificar ventajas ya existentes en vez de nivelarlas. Se cierra así el ciclo de mecanismo de dependencia de trayectoria descrito en el apartado 2.7. Las implicaciones de esta se estudiarán en el capítulo décimo.

CAPÍTULO 10: EL PIPELINE COMO MECANISMO DE APROPIACIÓN DIFERENCIAL

Los capítulos anteriores han ido describiendo cada fase de la cadena de procesamiento e identificado la barrera estructural que establecen. Este capítulo se centra en la síntesis de esas barreras desde un marco analítico propio con el fin de responder a la pregunta principal de en qué medida el proceso de Machine Learning aplicado a la publicidad automatizada en Marketplaces B2C genera ventajas competitivas asimétricas y sostenidas entre los actores que participan en él. El argumento desarrollado a continuación no sostiene que unos actores sean más grandes que otros, sino como la arquitectura de la cadena de procesamiento genera condiciones estructuralmente distintas para cada actor. Si bien el tamaño del actor tiende a tener correlación con la capacidad de mitigar las barreras, la variable decisiva es la arquitectura de datos.

10.1 Las seis barreras como sistema encadenado

Cada barrera ha sido evidenciada a través de literatura científica dependiendo de los requisitos técnicos de cada fase. Así se han establecido como mecanismos de exclusión competitiva del ecosistema de Marketplace B2C.

Estas barreras son muy relevantes desde el punto de vista competitivo gracias a su encadenamiento. No son independientes una de la otra por lo que no pueden mitigarse de forma aislada. Mitigar cada barrera depende de cómo se ha reducido la anterior, por lo que la posición de partida tiende a amplificarse a lo largo del proceso. Este encadenamiento convierte a este sistema en uno de exclusión progresiva, donde la posición previa va a condicionar en gran medida las posiciones posteriores (Arthur, 1989).

La Figura a continuación recoge estas seis barreras de forma esquematizada, recogiendo el nombre, naturaleza, requisito de mitigación y tipo de actor que puede aproximarse a mitigarlas

Tabla 4

Las seis barreras estructurales de la cadena de procesamiento publicitario en Marketplaces B2C

Fase	Barrera estructural	Naturaleza	Efecto de encadenamiento	Requisito de mitigación	¿Quién puede mitigarla?
Fase 1 Recogida	Barrera de granularidad	Pasiva. Ningún actor accede a la señal completa.	Sin señal rica, el vector de características de la siguiente fase es pobre y poco predictivo.	Datos propios externos (CRM, app, web propia).	Parcialmente: marcas con canales propios.
Fase 2 Preparación	Barrera de capacidad técnica y volumen	Pasiva. Requiere talento técnico y datos mínimos.	Sin vector preciso, los modelos predictivos de la siguiente fase producen estimaciones menos ajustadas.	Equipo técnico propio y volumen de campañas suficiente.	Parcialmente: marcas medianas con historial.
Fase 3 Modelización	Barrera de volumen de ejemplos etiquetados	Pasiva y creciente. Cada generación de modelos eleva el umbral.	Sin modelo calibrado, las decisiones de puja de la siguiente fase no son óptimas.	Millones de impresiones diarias propias.	Difícilmente: solo grandes anunciantes.
Fase 4 Optimización	Barrera de presupuesto experimental	Activa. Sin exploración no hay aprendizaje.	Sin política de puja óptima, el tráfico generado es insuficiente para	Margen para asumir el coste de oportunidad de la exploración.	Parcialmente: marcas con presupuesto holgado.

Fase	Barrera estructural	Naturaleza	Efecto de encadenamiento	Requisito de mitigación	¿Quién puede mitigarla?
			personalizar en la fase siguiente.		
Fase 5 Personalización	Barrera de volumen de tráfico mínimo	Acceso universal, resultado asimétrico.	Sin creatividad optimizada, la retroalimentación de la siguiente fase es pobre y el aprendizaje escaso.	Tráfico suficiente por variante creativa.	Solo actores con alto volumen de impresiones.
Fase 6 Retroalimentación	Barrera de apropiación del aprendizaje	Estructural. El aprendizaje fluye hacia la plataforma.	El ciclo beneficia a la plataforma, no al vendedor. La posición inicial se consolida y la brecha se amplía.	Control del ciclo completo con datos propios.	Solo la plataforma en su totalidad.

Nota. Elaboración propia a partir del análisis de los capítulos 4 a 9. Las barreras de granularidad, capacidad técnica, presupuesto experimental y volumen de tráfico admiten mitigación parcial por actores externos. Las barreras de volumen de ejemplos etiquetados y de apropiación del aprendizaje establecen el techo estructural del espectro: ningún actor externo puede eliminarlas completamente. La columna "Efecto de encadenamiento" ilustra por qué mitigar cada barrera depende en gran medida de haber reducido la anterior, convirtiendo el sistema en un mecanismo de exclusión progresiva (Arthur, 1989).

CAPÍTULO 11. CONCLUSIONES, LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

11.1 Conclusiones

Este trabajo partía de una pregunta ¿En qué medida el proceso de Machine Learning aplicado a la publicidad automatizada en Marketplace B2C genera ventajas competitivas asimétricas y sostenidas entre los actores que participan en él? El análisis desarrollado permite responder que las genera de forma estructural y creciente, a través de seis barreras estructurales.

Desde el análisis de cada fase se ha podido identificar la barrera concreta que se introduce y los actores capaces de mitigarla. En la fase de recogida de datos, la barrera de la granularidad afecta por igual a todos los vendedores, ya que ninguno tiene acceso a la señal completa de la plataforma, aunque las marcas con canales propios pueden complementarla parcialmente con datos de CRM. En la fase de preparación, la barrera de la capacidad técnica y el volumen excluye a los vendedores que carecen de un equipo técnico o de datos históricos suficientes para crear variables predictivas fiables mediante

la ingeniería de características. En la fase de modelización, la barrera del volumen de ejemplos etiquetados limita el acceso a arquitecturas de tercera generación, como *Wide & Deep*, *DeepFM* o *DLRM*, a los actores con millones de impresiones diarias, dejando al resto dependientes de las estimaciones genéricas de la plataforma. En la fase de optimización, la barrera del presupuesto experimental impide a los vendedores con márgenes ajustados explorar estrategias que utilicen algoritmos de tipo *Multi-Armed Bandit* o aprendizaje por refuerzo, dejándolos atrapados en pujas estáticas. En la fase de personalización, la barrera del volumen mínimo de tráfico implica que los modelos generativos y los algoritmos de experimentación adaptativa solo producen resultados fiables para los actores con tráfico suficiente por variante. Por último, en la fase de retroalimentación, la barrera de la apropiación del aprendizaje beneficia estructuralmente a la plataforma, que integra los resultados de todos los participantes simultáneamente, a diferencia de lo que ocurre con cualquier vendedor individual. El hallazgo fundamental reside en que todas estas son componentes de un sistema de encadenamiento. Esto significa que la dificultad de mitigar una barrera posterior tiene una alta dependencia del grado en que se ha mitigado la anterior.

Estas barreras son estructurales y no temporales. Así lo establecen dos mecanismos teóricos. El primero es la inimitabilidad de los recursos que hacen falta para mitigarlas. Recursos que cumplen con los criterios del marco VRIO de Barney (1991) y no pueden replicarse con inversión puntual. El segundo es la dinámica de refuerzo acumulativo del *path dependence* de Arthur (1989), amplificada por los rendimientos crecientes de escala en el aprendizaje que Varian (2018) identifica en los datos: quien mitiga mejor las barreras iniciales llega a las siguientes en mejor posición, aprende más rápido en cada iteración y amplía la brecha respecto a quienes no pudieron hacerlo. Por lo tanto, esta brecha no se cierra con el tiempo, se amplía.

El resultado del análisis no se basa en una tipología de actores, es un concepto más complejo. Se trata de un espectro continuo de apropiación diferencial donde la posición de cada actor establece cuántas barreras ha podido mitigar y con qué profundidad. Esta mitigación no se determina tan solo por su tamaño, sino por la combinación de historial de datos acumulados, capacidad técnica y margen para la experimentación. En un extremo se encuentra la plataforma, único actor para el cual las barreras no existen. La plataforma es quien las construye, controla señales de todos los actores y se apropia del aprendizaje. Los demás actores toman posiciones intermedias, sin

ser capaces de eliminar las barreras al completo, pero sí de reducir la brecha respecto a la plataforma en función de recursos e historial acumulado.

De todo esto, destaca una conclusión muy relevante en la práctica empresarial. La automatización que la plataforma ofrece reduce la fricción del acceso, pero consolida una dependencia estructural. Un vendedor con mucha actividad en la plataforma contribuye en gran medida al aprendizaje de la infraestructura. El problema es que esto no se traduce necesariamente en una mejora de su propia posición competitiva. El sistema no nivela, estratifica.

Esta dinámica se hace patente en los tres ecosistemas analizados a lo largo de este estudio. En Amazon, los pequeños vendedores que activan la segmentación automática y las pujas dinámicas dejan que la plataforma tome todas las decisiones clave del proceso, desde la estimación de la probabilidad de clic hasta la selección del material publicitario más adecuado. Mientras tanto, Amazon perfecciona continuamente sus modelos utilizando datos de todos los vendedores. Una marca de tamaño medio con sus propios datos de CRM puede mejorar algo su situación y experimentar con diferentes estrategias de puja, pero sigue sin tener acceso a la señal granular que realmente determina su posición en la subasta. Solo los grandes anunciantes con sus propios equipos técnicos pueden acercarse a controlar ciertas fases del proceso, aunque nunca alcanzan el nivel de control que posee la propia plataforma. Algo muy similar ocurre en Alibaba a través de su ecosistema publicitario Alimama, con la diferencia de que los datos de comportamiento de compra online y offline están aún más integrados, lo que hace aún más difícil para cualquier actor externo acercarse a la posición de la plataforma. En Google, la lógica es la misma: los anunciantes que utilizan únicamente las herramientas automatizadas de Google Ads, como *Smart Bidding* o *Performance Max*, están cediendo el control de las fases de optimización y personalización a la plataforma. Consiguen resultados razonables a corto plazo, pero no acumulan aprendizaje propio que pueda llevarse consigo fuera del ecosistema de Google (Amazon Ads, 2025; Google Ads Help, s. f.-b).

11.2 Limitaciones

Este trabajo se ha encontrado con limitaciones que deben ser reconocidas explícitamente. La principal es la ausencia de validación empírica. El carácter principal es el teórico-conceptual, adquirido establecer las seis barreras y el espectro de apropiación diferencial, constituye un análisis fundamentado en la revisión de literatura científica. Las hipótesis planteadas a partir de los conceptos desarrollados son coherentes con la

evidencia teórica, pero requerirían un contraste empírico si se quieren confirmar de manera definitiva.

La segunda limitación es análisis concentrado de este trabajo en los Marketplaces B2C de mayor escala, destacando especialmente Amazon, Alibaba y Google. Esto hace que el marco propuesto sí que sea potencialmente aplicable a otros ecosistemas, pero las barreras planteadas pueden variar en intensidad dependiendo del tamaño y madurez del Marketplace. Por lo tanto, la generalización de las conclusiones expuestas requiere cautela.

La tercera limitación tiene que ver con la perspectiva temporal del análisis. El espectro de apropiación diferencial que se propone en este trabajo describe cómo están posicionados los distintos actores en un momento dado, pero no explica cómo evoluciona esa posición con el tiempo ni qué tendría que pasar para que un actor pudiera mejorarla. Es decir, el marco es estático en un fenómeno que por naturaleza es dinámico.

11.3 Futuras líneas de investigación

La línea de investigación futura más clara viene dada por la principal limitación del trabajo: la validación empírica de los conceptos e hipótesis planteadas. El espectro de apropiación diferencial podría estudiarse a través de un estudio cuantitativo en el que se clasificaran los distintos tipos de actores. Para ello se podría medir su posición relativa dentro del espectro mediante indicadores de rendimiento observables.

Una segunda línea relevante podría ser un análisis comparativo de distintos Marketplaces B2C de distinta escala y madurez. Esto podría determinar si las seis barreras establecidas se establecen con la misma intensidad tanto en los Marketplaces emergentes como en aquellos más consolidados.

La tercera línea de investigación surge en el contexto regulatorio actual. El *Digital Markets Act* europeo obliga a las grandes plataformas designadas como *gatekeepers*, entre ellas Amazon y Google, a dar a los vendedores acceso estructurado a ciertos datos que han sido generados dentro de la plataforma. Esto podría permitirles trabajar con señales mucho más ricas. Esta regulación abriría la pregunta de hasta qué punto podría reducir esta regulación las barreras más profundas que este trabajo ha establecido. En especial tanto la barrera de granularidad como la de apropiación del aprendizaje. La respuesta no es obvia, ya que, aunque un vendedor accediera a más datos propios, la plataforma seguiría acumulando datos de todos los actores simultáneamente. Por lo tanto, determinar

si el DMA reduce la asimetría estructural de forma efectiva y diferencial o si esta acaba manteniéndose, establece una línea de investigación muy relevante.

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, FERNANDO LAPETRA MURCIA, estudiante de Psicología y ADE de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "[Título del trabajo]", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT, Gemini y Claude u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

- 1. Brainstorming de ideas de investigación:** me ayudó a idear y esbozar posibles áreas de investigación, especialmente al principio del trabajo, cuando todavía estaba definiendo el enfoque y buscando una aportación original.
- 2. Referencias:** lo usé junto con otras herramientas como Google Scholar para identificar referencias preliminares sobre los temas del trabajo, que luego busqué, leí y validé de forma individual.
- 3. Metodólogo:** me sirvió para descubrir métodos y marcos teóricos que podían encajar con el problema de investigación, como el marco VRIO o el concepto de path dependence, que luego apliqué y desarrollé por mi cuenta.
- 4. Estudios multidisciplinares:** lo utilicé para entender mejores perspectivas de otras disciplinas como la economía industrial, la estrategia empresarial o las ciencias de la computación, que no son el núcleo de ADE pero resultaban necesarias para el análisis.
- 5. Constructor de plantillas:** me ayudó a diseñar el formato de algunas secciones del trabajo, en particular las figuras, tablas y diagramas.
- 6. Sintetizador y divulgador de libros complicados:** lo usé para entender papers técnicos de alta complejidad, sobre todo los relacionados con redes neuronales y aprendizaje por refuerzo. La selección de cada fuente, su lectura y su uso en el trabajo han sido decisiones mías.

7. Generador de problemas de ejemplo: me ayudó a ilustrar conceptos técnicos difíciles con ejemplos concretos aplicados al contexto de los Marketplaces, lo que me facilitó luego redactarlos con mis propias palabras.

8. Revisor: lo usé para recibir sugerencias sobre cómo mejorar el texto, la estructura y la claridad del trabajo, sin delegar en ningún momento la elaboración ni la interpretación de los contenidos.

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. 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: 03/06/2026

Firma:

A handwritten signature in black ink, consisting of several overlapping, stylized lines that form a unique, abstract shape.

BIBLIOGRAFÍA

AiHello. (2025). How does the Amazon PPC auction work?

<https://www.aihello.com/resources/blog/how-does-the-amazon-ppc-auction-work/>

Amazon Ads. (2024a). How AI is changing the ad experience.

<https://advertising.amazon.com/resources/whats-new/how-ai-is-changing-the-ad-experience>

Amazon Ads. (2024b, 7 de noviembre). Show your display ads to audiences who are most likely to consider and buy from your business (Dynamic segments).

<https://advertising.amazon.com/en-gb/resources/whats-new/dynamic-segments>

Amazon Ads. (2025a). Guía de pujas dinámicas (aumentar y reducir) con Sponsored Products. <https://advertising.amazon.com/es-es/library/guides/dynamic-bidding-sponsored-products>

Amazon Ads. (2025b, 12 de agosto). Scale personalized ads with responsive e-commerce creatives on Amazon DSP. <https://advertising.amazon.com/resources/whats-new/personalize-ads-with-amazon-dsp-responsive-e-commerce-creatives>

Amazon Ads. (s. f.-a). Ad campaign attribution.

<https://advertising.amazon.co.uk/help/GX7KDKHMQYJM385>

Amazon Ads. (s. f.-b). Amazon Attribution: Medir el impacto de tus canales externos.

<https://advertising.amazon.com/es-es/solutions/products/amazon-attribution>

Amazon Ads. (s. f.-c). Amazon DSP: Advertise with a demand-side platform.

<https://advertising.amazon.com/ja-jp/solutions/products/amazon-dsp>

Amazon Ads. (s. f.-d). Attribution methodology.

<https://advertising.amazon.com/help/G4YK9L2G4NXDD7SC>

Amazon Ads. (s. f.-e). Conversion attribution.

<https://advertising.amazon.com/help/G3BB9TWP5KC375TJ>

Amazon Ads. (s. f.-f). Descripción de Amazon Ads: una guía de nuestros productos publicitarios. <https://advertising.amazon.com/es-es/library/guides/basics-of-success-understanding-amazon-advertising>

Amazon Ads. (s. f.-g). Display ads: Llega a audiencias en Amazon y más allá.

<https://advertising.amazon.com/es-es/products/display-ads>

Amazon Ads. (s. f.-h). Guía sobre la segmentación con Sponsored Products.

<https://advertising.amazon.com/es-es/library/guides/targeting-with-sponsored-products>

Amazon Ads. (s. f.-i). ¿Qué es el costo publicitario de ventas (ACoS)?

<https://advertising.amazon.com/es-co/library/guides/acos-advertising-cost-of-sales>

Amazon Ads. (s. f.-j). Sponsored ads overview.

<https://advertising.amazon.com/help/GBLW5Z48RQHEDCW5>

Amazon Ads. (s. f.-k). Sponsored Brands: Increase brand awareness.

<https://advertising.amazon.com/solutions/products/sponsored-brands>

Amazon Ads. (s. f.-l). Sponsored Products: Help increase product sales.

<https://advertising.amazon.com/solutions/products/sponsored-products>

Amazon Ads. (s. f.-m). What is a demand-side platform (DSP)? A complete guide.

<https://advertising.amazon.com/library/guides/demand-side-platform>

Amazon Ads. (s. f.-n). Your complete guide to Sponsored Brands.

<https://advertising.amazon.com/library/guides/sponsored-brands-what-to-know>

Amazon.com, Inc. (2025). Amazon 2024 annual report.

https://s2.q4cdn.com/299287126/files/doc_financials/2025/ar/Amazon-2024-Annual-Report.pdf

Apple. (2021). User privacy and data use. <https://developer.apple.com/app-store/user-privacy-and-data-use/>

Arthur, W. B. (1989). Competing technologies, increasing returns, and lock-in by historical events. *The Economic Journal*, 99(394), 116–131.

<https://doi.org/10.2307/2234208>

Barney, J. B. (1991). Firm resources and sustained competitive advantage. *Journal of Management*, 17(1), 99–120. <https://doi.org/10.1177/014920639101700108>

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Cai, H., Ren, K., Zhang, W., Malialis, K., Wang, J., Yu, Y., & Guo, D. (2017). Real-time bidding by reinforcement learning in display advertising. En *Proceedings of the 10th*

- ACM International Conference on Web Search and Data Mining (WSDM) (pp. 661–670). ACM. <https://doi.org/10.1145/3018661.3018702>
- Cecere, G., Corrocher, N., & Zucchella, A. (2024). Artificial intelligence and algorithmic bias? Field tests on online advertising. *Technological Forecasting & Social Change*, 198, 122–142. <https://doi.org/10.1016/j.techfore.2023.122142>
- Chaney, A. J. B., Stewart, B. M., & Engelhardt, B. E. (2018). How algorithmic confounding in recommendation systems increases homogeneity and decreases utility. *En Proceedings of the 12th ACM Conference on Recommender Systems (RecSys)* (pp. 224–232). ACM. <https://arxiv.org/abs/1710.11214>
- Chandon, P., Chtourou, M. S., & Fortin, D. R. (2003). Effects of configuration and exposure levels on responses to web advertisements. *Journal of Advertising Research*, 43(2), 217–229. <https://doi.org/10.2501/JAR-43-2-217-229>
- Channel Key. (2025, 13 de marzo). Mastering Amazon AI advertising: A brief guide to smarter campaigns. <https://www.channelkey.com/post/mastering-amazon-ai-advertising-a-brief-guide-to-smarter-campaigns>
- Chapelle, O., Manavoglu, E., & Rosales, R. (2015). Simple and scalable response prediction for display advertising. *ACM Transactions on Intelligent Systems and Technology*, 5(4), Artículo 61. <https://doi.org/10.1145/2532128>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *En Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Cheng, H.-T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., Anderson, G., Corrado, G., Chai, W., Ispir, M., Anil, R., Haque, Z., Hong, L., Jain, V., Liu, X., & Shah, H. (2016). Wide & deep learning for recommender systems. *En Proceedings of the 1st Workshop on Deep Learning for Recommender Systems (DLRS)* (pp. 7–10). ACM. <https://doi.org/10.1145/2988450.2988454>
- 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>

- eComEngine. (2021, 20 de agosto). CTR, CVR, ACoS, ROAS: Your guide to Amazon PPC management. <https://www.ecomengine.com/blog/amazon-ppc-management>
- Edelman, B., Ostrovsky, M., & Schwarz, M. (2007). Internet advertising and the generalized second-price auction: Selling billions of dollars worth of keywords. *American Economic Review*, 97(1), 242–259. <https://doi.org/10.1257/aer.97.1.242>
- 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-080315-015234>
- Geng, T., Yan, J., Liu, W., & Chen, Z. (2021). Bandit-based experimentation system for online advertising. En *Proceedings of the 35th AAAI Conference on Artificial Intelligence* (pp. 15748–15756). AAAI Press. <https://cdn.aaai.org/ojs/17854/17854-13-21348-1-2-20210518.pdf>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (2.^a ed.). O'Reilly Media.
- Google. (2024). Privacy Sandbox: Building a more private web. <https://privacysandbox.com/>
- Google Ads Help. (s. f.-a). Impresiones: definición. <https://support.google.com/google-ads/answer/6320?hl=es>
- Google Ads Help. (s. f.-b). Porcentaje de clics (CTR): definición. <https://support.google.com/google-ads/answer/2615875?hl=es>
- Google Ads Help. (s. f.-c). Tasa de conversión: definición. <https://support.google.com/google-ads/answer/2684489?hl=es>
- 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>
- Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: A factorization-machine based neural network for CTR prediction. En *Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI)* (pp. 1725–1731). <https://doi.org/10.24963/ijcai.2017/239>
- Hagiu, A., & Wright, J. (2015). Marketplace or reseller? *Management Science*, 61(1), 184–203. <https://doi.org/10.1287/mnsc.2014.1929>

- He, X., Pan, J., Jin, O., Xu, T., Liu, B., Xu, T., Shi, Y., Atallah, A., Herbrich, R., Bowers, S., & Candela, J. Q. (2014). Practical lessons from predicting clicks on ads at Facebook. En Proceedings of the 8th International Workshop on Data Mining for Online Advertising (ADKDD) (pp. 1–9). ACM. <https://doi.org/10.1145/2648584.2648589>
- Huang, M., & Liu, T. (2022). Subjective or objective: How the style of text in computational advertising influences consumer behaviors? *Fundamental Research*, 2(1), 144–153. <https://doi.org/10.1016/j.fmre.2021.11.004>
- IAB Europe. (2021). Guide to ad fraud (v1.2). <https://iabeurope.eu/wp-content/uploads/IAB-Europe-Guide-to-Ad-Fraud-1-2.pdf>
- IAB Europe. (2023). IAB Europe's retail media 101 guide. <https://iabeurope.eu/wp-content/uploads/2023/09/IAB-Europes-Retail-Media-101-Guide-FINAL.pdf>
- Investopedia. (2024, 26 de agosto). What is an impression in online advertising, how to count them (W. Kenton, Ed.). <https://www.investopedia.com/terms/i/impression.asp>
- Investopedia. (2025, 22 de agosto). Understanding cost per click (CPC): Formula, alternatives, and benefits. <https://www.investopedia.com/terms/c/cpc.asp>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30, 3146–3154. <https://proceedings.neurips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>
- Klimashevskaja, A., Jannach, D., Elahi, M., & Trattner, C. (2024). A survey on popularity bias in recommender systems. *User Modeling and User-Adapted Interaction*. <https://doi.org/10.1007/s11257-024-09406-0>
- Kreps, J., Narkhede, N., & Rao, J. (2011). Kafka: A distributed messaging system for log processing. En Proceedings of the NetDB Workshop at VLDB. <https://www.cs.columbia.edu/~du/ds/assets/papers/kafka.pdf>
- Ktena, S. I., Tejani, A., Theis, L., Myana, P. K., Dilipkumar, D., Huszár, F., Yoo, S., & Shi, W. (2019). Addressing delayed feedback for continuous training with neural networks in CTR prediction. En Proceedings of the 13th ACM Conference on

- Recommender Systems (RecSys) (pp. 187–195). ACM.
<https://doi.org/10.1145/3298689.3347002>
- Kuhn, M., & Johnson, K. (2013). Applied predictive modeling. Springer.
<https://doi.org/10.1007/978-1-4614-6849-3>
- Lambrecht, A., & Tucker, C. E. (2015). Can big data protect a firm from competition? SSRN Working Paper. <https://doi.org/10.2139/ssrn.2705530>
- Li, H., & Kannan, P. K. (2014). Attributing conversions in a multichannel online marketing environment: An empirical model and a field experiment. *Journal of Marketing Research*, 51(1), 40–56. <https://doi.org/10.1509/jmr.13.0050>
- Ma, X., Zhao, L., Huang, G., Wang, Z., Hu, Z., Zhu, X., & Gai, K. (2018). Entire space multi-task model: An effective approach for estimating post-click conversion rate. En *Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval* (pp. 1137–1140). ACM.
<https://doi.org/10.1145/3209978.3210104>
- Mabaya. (s. f.). AliExpress sponsored product ads: How it works.
<https://www.mabaya.com/aliexpress-sponsored-product-ads/>
- Mabaya. (2019, 18 de junio). What is the best model for your sponsored product ads offering? <https://www.mabaya.com/what-is-the-best-model-for-your-sponsored-product-ads-offering/>
- Marketplace Pulse. (s. f.). Amazon advertising services sales 2020–2025.
<https://www.marketplacepulse.com/stats/amazon-advertising-services-sales>
- McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., Nie, L., Phillips, T., Davydov, E., Golovin, D., Chikkerur, S., Liu, D., Wattenberg, M., Hrafinkelsson, A. M., Boulos, T., & Kubica, J. (2013). Ad click prediction: A view from the trenches. En *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1222–1230). ACM.
<https://doi.org/10.1145/2487575.2488200>
- Media Rating Council. (2020). Invalid traffic detection and filtration standards addendum update.

<https://mediaratingcouncil.org/sites/default/files/Standards/IVT%20Addendum%20Update%20062520.pdf>

Moon, H., Lee, T., Seo, J., Park, C., Eo, S., Aiyanyo, I. D., Jeong, J., Lim, H., & Park, K. (2022). Return on advertising spend prediction with task decomposition-based LSTM model. *Mathematics*, 10(10), Artículo 1637.

<https://doi.org/10.3390/math10101637>

Naumov, M., Mudigere, D., Shi, H., Huang, J., Sundaraman, N., Park, J., Wang, X., Gupta, U., Wu, C.-J., Azzolini, A. G., Dzhulgakov, D., Malleovich, A., Cherniavskii, I., Lu, Y., Krishnamoorthi, R., Yu, A., Kondratenko, V., Pereira, S., Chen, X., ... Smelyanskiy, M. (2019). Deep learning recommendation model for personalization and recommendation systems. arXiv. <https://arxiv.org/abs/1906.00091>

Provost, F., & Fawcett, T. (2013). *Data science for business*. O'Reilly Media.

Richardson, M., Dominowska, E., & Ragno, R. (2007). Predicting clicks: Estimating the click-through rate for new ads. En *Proceedings of the 16th International Conference on World Wide Web (WWW)* (pp. 521–530). ACM.

<https://doi.org/10.1145/1242572.1242643>

Schein, A. I., Popescul, A., Ungar, L. H., & Pennock, D. M. (2002). Methods and metrics for cold-start recommendations. En *Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 253–260). ACM. <https://doi.org/10.1145/564376.564421>

Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden technical debt in machine learning systems. *Advances in Neural Information Processing Systems*, 28, 2503–2511. <https://proceedings.neurips.cc/paper/2015/hash/86df7dcfd896fcaf2674f757a2463eba-Abstract.html>

Seller Labs. (2025, 21 de agosto). Amazon PPC automation in 2025: A beginner's guide with Ad Genius. <https://www.sellerlabs.com/blog/amazon-ppc-automation-beginners-2025/>

Smith, E., & Larsson, R. (2019). Reinforcement learning for real-time bidding [Tesis de máster, Lund University]. Lund University Publications. <https://lup.lub.lu.se/student-papers/search/publication/8986392>

Spring GDS España. (2025, 26 de junio). Guía de Amazon Ads para e-commerce.

<https://www.spring-gds.com/es/blog/guia-de-amazon-ads/>

Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction (2.^a ed.).

MIT Press. <http://incompleteideas.net/book/the-book-2nd.html>

Varian, H. R. (2018). Artificial intelligence, economics, and industrial organization.

NBER Working Paper No. 24839. National Bureau of Economic Research.

<https://doi.org/10.3386/w24839>

Willens, M. (2025, 5 de noviembre). Retail media ad spending forecast and trends H2

2025. EMARKETER. [https://www.emarketer.com/content/retail-media-ad-spending-](https://www.emarketer.com/content/retail-media-ad-spending-forecast-trends-h2-2025)

[forecast-trends-h2-2025](https://www.emarketer.com/content/retail-media-ad-spending-forecast-trends-h2-2025)

Yang, Y., Kabir, M., Han, Z., & Zhang, Z. (2022). Click-through rate prediction in

online advertising: A systematic literature review. *Information Processing &*

Management, 59(3), Artículo 102594. <https://doi.org/10.1016/j.ipm.2021.102594>

Zaharia, M., Xin, R. S., Wendell, P., Das, T., Armbrust, M., Dave, A., Meng, X., Rosen,

J., Venkataraman, S., Franklin, M. J., Ghodsi, A., Gonzalez, J., Shenker, S., & Stoica, I.

(2016). Apache Spark: A unified engine for big data processing. *Communications of the*

ACM, 59(11), 56–65. <https://doi.org/10.1145/2934664>

Zhao, B. (2025). Optimizing click-through rates in online advertising using multi-armed

bandits. *ITM Web of Conferences*, 70, Artículo 03009.

<https://doi.org/10.1051/itmconf/20257003009>