



# Módulo 3. Fundamentos de la IA en la optimización del marketing mobile

☰ 1. Fundamentos de la IA en la optimización del marketing mobile

☰ 2. Personalización y toma de decisiones basada en IA

☰ Referencias

# 1. Fundamentos de la IA en la optimización del marketing mobile

---

En los entornos actuales de marketing digital, las decisiones vinculadas a la adquisición, retención y monetización de usuarios se apoyan cada vez más en el uso de sistemas automatizados capaces de procesar grandes volúmenes de información en tiempo real. En ese marco, la incorporación de **inteligencia artificial**, especialmente en ecosistemas *mobile*, redefine la manera en que se diseñan, ejecutan y optimizan las estrategias de interacción con usuarios. A partir de lo trabajado en módulos anteriores —donde se abordaron enfoques de *engagement* y lógicas de experimentación iterativa—, en esta unidad se avanza hacia una capa analítica que permite anticipar comportamientos y ajustar dinámicamente las acciones de *marketing*.

En la práctica profesional, equipos de *mobile marketing* enfrentan situaciones donde deben decidir qué creatividad mostrar, a qué

segmento impactar o cuánto invertir en adquisición sin contar con certezas completas. En ese contexto, los modelos basados en **machine learning** permiten transformar datos históricos y señales tempranas en predicciones accionables. Esto habilita nuevas formas de intervención sobre el ciclo de vida del usuario, integrando variables como comportamiento de navegación, interacción con contenidos y patrones de consumo dentro de aplicaciones.

A su vez, la evolución de herramientas basadas en IA introduce la posibilidad de automatizar procesos que anteriormente requerían intervención manual constante. Desde la generación de múltiples variantes de anuncios mediante *dynamic creatives* hasta la estimación del valor futuro de un usuario a través de modelos de **predictive LTV**, las organizaciones pueden ajustar sus estrategias con mayor precisión y menor latencia. Este enfoque no solo optimiza recursos, sino que también permite construir experiencias más alineadas con los intereses y recorridos reales de cada usuario.

En este marco, comprender cómo funcionan estas tecnologías y cómo se integran en las decisiones de marketing resulta relevante para abordar problemas concretos del ejercicio profesional: ¿cómo priorizar inversiones en adquisición?, ¿qué señales tempranas indican que un usuario será valioso a largo plazo?, ¿de qué manera adaptar los mensajes en función del

comportamiento observado? A lo largo de esta unidad se desarrollarán herramientas y conceptos que permiten responder a estos interrogantes, articulando fundamentos técnicos con su aplicación en escenarios reales de **optimización, personalización** y toma de decisiones basada en datos.

## Creatividades dinámicas impulsadas por IA

Las creatividades dinámicas, conocidas como *dynamic creatives*, constituyen un enfoque de producción y optimización de anuncios basado en el uso de sistemas de **inteligencia artificial** que generan múltiples variantes de contenido a partir de combinaciones automatizadas. En este esquema, los elementos de una pieza publicitaria —como textos, imágenes o formatos— se descomponen en unidades que pueden ser recombinadas según distintos criterios. De este modo, se habilita una lógica de experimentación continua donde las creatividades se configuran dinámicamente en función del contexto de cada usuario. Este proceso se vincula con el uso de modelos de *machine learning*, que permiten identificar patrones de rendimiento y orientar la selección de variantes con base en datos históricos y en tiempo real.

En términos operativos, la automatización de variantes implica que los equipos de marketing definen un conjunto inicial de recursos —copys, imágenes, llamados a la acción— que luego son procesados por sistemas de *IA generativa* para producir combinaciones posibles. Esta lógica habilita la producción simultánea de múltiples versiones de una misma campaña, lo que amplía el espectro de experimentación sin incrementar proporcionalmente los recursos humanos involucrados. Así, el proceso creativo se desplaza hacia una instancia de diseño de inputs, mientras que la generación y combinación se delega en sistemas automatizados.

A su vez, la integración con sistemas de **automatización** permite que estas variantes se activen en función de reglas o predicciones específicas, como la probabilidad de conversión o el comportamiento reciente del usuario dentro de la aplicación. Este enfoque articula datos, modelos y ejecución en una misma lógica operativa, donde las decisiones se basan en señales observables y no únicamente en configuraciones predefinidas. De este modo, las campañas adquieren una mayor capacidad de adaptación frente a cambios en el comportamiento del usuario.

En este contexto, las creatividades dinámicas se inscriben dentro de una tendencia más amplia vinculada a la **personalización** a escala. Según el equipo de IEBS (2025), la aplicación de IA en marketing permite adaptar mensajes y contenidos en función de

la intención y el comportamiento de los usuarios, lo que incrementa la relevancia de las interacciones y mejora los resultados de negocio

**Tabla 1. Componentes de las creatividades dinámicas impulsadas por IA.**

Componente	Función en el sistema	Ejemplo de aplicación
Copys dinámicos	Generación de variantes textuales	Mensajes personalizados según segmento
Imágenes variables	Adaptación visual según contexto	Productos destacados según historial
Formatos adaptativos	Ajuste del diseño según dispositivo	Anuncios verticales u horizontales
Motor de optimización	Selección de la mejor combinación	Priorización de anuncios con mayor CTR

Fuente: elaboración propia con base en IEBS, 2025

**La optimización en tiempo real constituye otro de los ejes centrales de las *dynamic creatives*. A partir del análisis**

**continuo de datos —como clics, conversiones o tiempo de interacción—, los sistemas ajustan automáticamente qué variantes se muestran y a qué usuarios. Este proceso se apoya en modelos de **analítica predictiva**, que permiten anticipar qué combinación tiene mayor probabilidad de generar resultados positivos en cada contexto. En consecuencia, la toma de decisiones se integra dentro de un flujo automatizado que reduce los tiempos de respuesta y mejora la eficiencia de las campañas.**

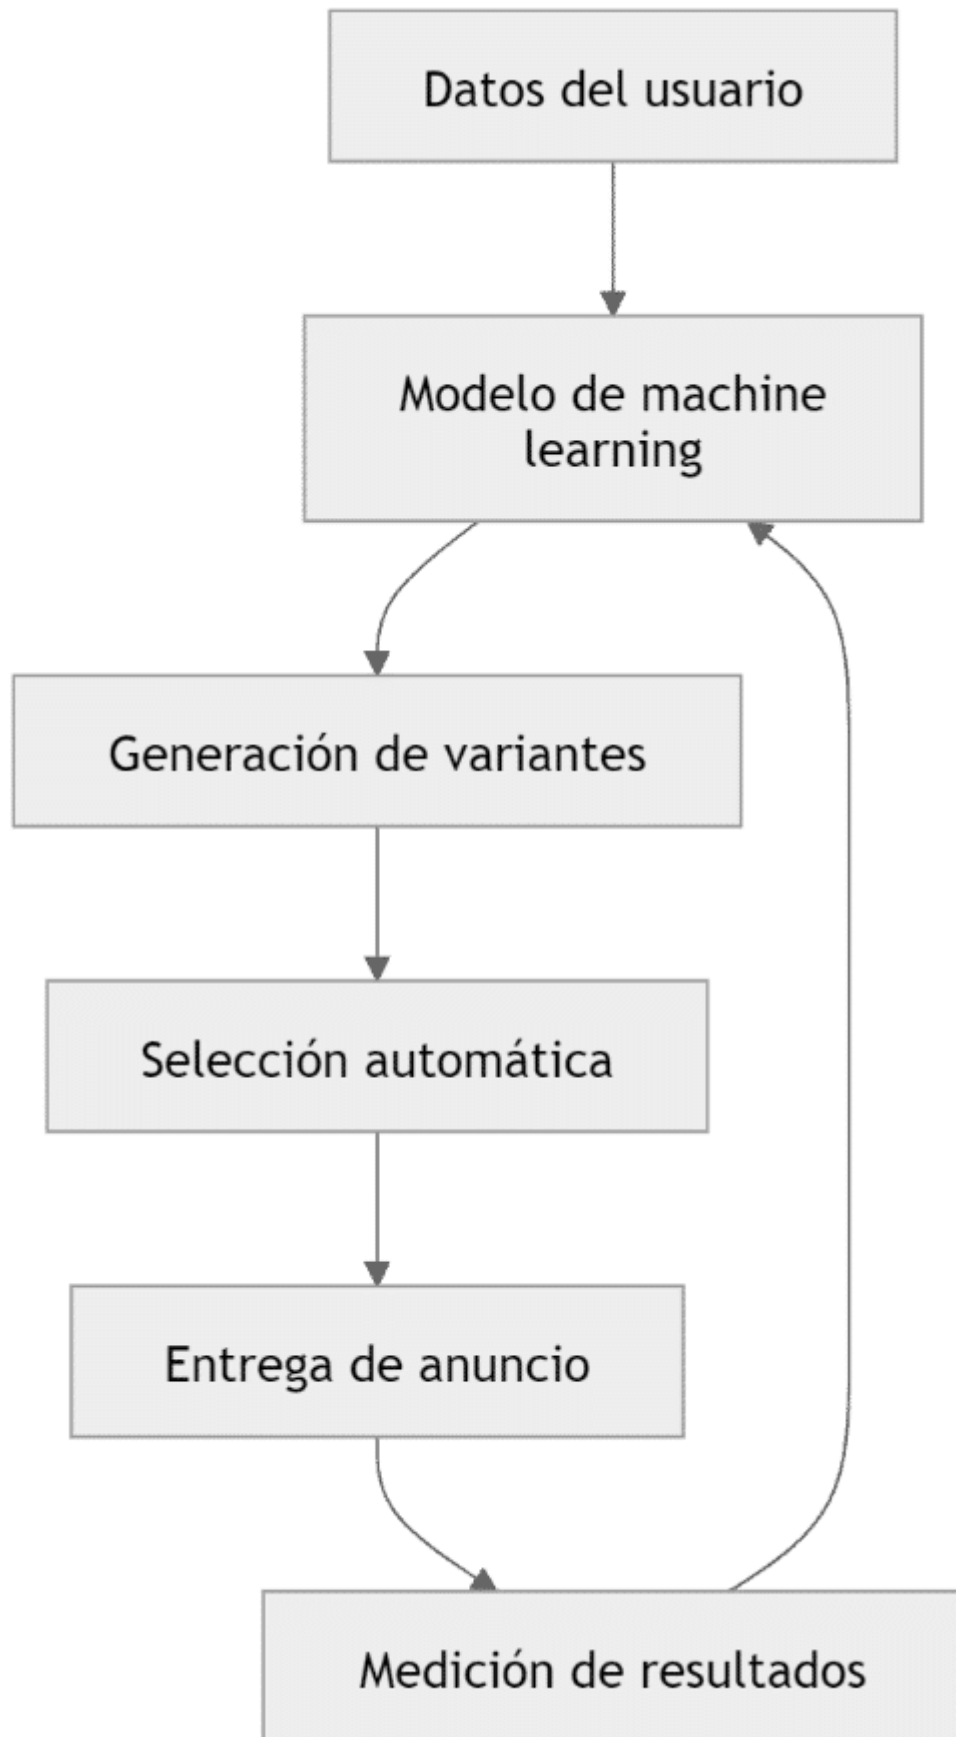
Este tipo de optimización continua se articula con la capacidad de los sistemas de detectar patrones invisibles a simple vista. A medida que se acumulan datos de interacción, los modelos refinan sus predicciones y ajustan la distribución de las variantes creativas. Esto permite sostener procesos de mejora progresiva donde cada iteración incorpora aprendizaje acumulado, fortaleciendo la capacidad del sistema para responder a escenarios dinámicos.

En el plano operativo, esta lógica implica que los equipos de marketing ya no trabajan únicamente sobre resultados finales, sino también sobre indicadores intermedios que permiten anticipar comportamientos. Por ejemplo, tasas de clics tempranas o niveles de interacción inicial pueden utilizarse como

señales para redistribuir la inversión hacia aquellas variantes con mejor desempeño esperado. De este modo, la optimización deja de ser reactiva y se convierte en un proceso anticipatorio.

A partir de lo anterior, las creatividades dinámicas se integran dentro de un ecosistema donde producción, análisis y ejecución funcionan de manera coordinada. Esta articulación permite escalar campañas sin perder capacidad de ajuste, manteniendo coherencia entre los objetivos estratégicos y las acciones implementadas en cada punto de contacto con el usuario.

## **Figura 1. Flujo de optimización de creatividades dinámicas**



**A partir de este flujo, se observa cómo la optimización de creatividades dinámicas se estructura como un proceso cíclico donde cada interacción del usuario alimenta nuevamente al sistema. Este mecanismo permite que las decisiones no se definan de manera estática, sino que se ajusten continuamente en función del rendimiento observado. La integración entre datos, modelos y ejecución configura un entorno donde la mejora se produce de manera progresiva, incorporando aprendizajes en cada iteración.**

En el ejercicio profesional, este tipo de arquitectura habilita estrategias de marketing más adaptativas, donde la selección de creatividades responde a señales concretas del comportamiento del usuario. Equipos que operan campañas *mobile* pueden, por ejemplo, modificar automáticamente los mensajes en función de la etapa del *funnel* o del nivel de interacción registrado. De este modo, las *dynamic creatives* se consolidan como un recurso que

articula **optimización, automatización y personalización** dentro de un mismo sistema operativo.

## **Modelos de Predictive LTV en *mobile marketing***

El concepto de *Lifetime Value* predictivo, o *predictive LTV*, refiere a la estimación del valor económico futuro que un usuario generará a lo largo de su relación con una aplicación, a partir de datos disponibles en etapas tempranas de su interacción. En entornos de *mobile marketing*, esta estimación se construye mediante modelos de ***machine learning*** que procesan señales iniciales —como eventos dentro de la app o primeras conversiones— para anticipar comportamientos a largo plazo. Según Adjust (Wetzler, 2022), estos modelos permiten proyectar resultados futuros incluso cuando la información disponible es limitada, como ocurre en contextos donde los datos se encuentran anonimizados o restringidos.

**Desde una perspectiva operativa, el predictive LTV se apoya en el análisis de múltiples variables que funcionan como indicadores tempranos del valor del usuario. Entre ellas, se destacan el comportamiento inicial dentro de la aplicación,**

**los niveles de retención y los patrones de monetización observados en los primeros días. Estas variables se integran en modelos de **analítica predictiva** que identifican correlaciones entre acciones tempranas y resultados futuros, permitiendo construir estimaciones más robustas que aquellas basadas únicamente en datos históricos agregados.**

La capacidad de anticipar el valor del usuario adquiere relevancia en escenarios donde el acceso a datos completos resulta limitado. Por ejemplo, en entornos como iOS con el uso de SKAdNetwork, los datos disponibles se concentran en ventanas temporales acotadas y bajo condiciones de anonimización. Frente a esta situación, los modelos de predictive LTV permiten extrapolar comportamientos futuros a partir de información parcial, utilizando patrones aprendidos de otros usuarios o cohortes similares. Este enfoque facilita la toma de decisiones sin necesidad de esperar ciclos completos de monetización.


A partir de lo anterior, el uso del *predictive LTV* transforma la lógica de evaluación de campañas, desplazando el foco desde métricas retrospectivas hacia estimaciones anticipadas. Esto implica que las decisiones de inversión, segmentación y optimización pueden realizarse en etapas tempranas del ciclo de

vida del usuario, reduciendo tiempos de espera y mejorando la eficiencia en la asignación de recursos.

**Tabla 2. Variables clave en modelos de *predictive LTV***

Variable	Descripción	Aplicación en marketing mobile
Comportamiento temprano	Interacciones iniciales dentro de la app	Identificación de usuarios de alto valor
Retención	Frecuencia y duración de uso	Predicción de permanencia en la aplicación
Monetización	Compras o ingresos generados	Estimación de ingresos futuros
Cohortes similares	Agrupación por patrones compartidos	Extrapolación de comportamientos

Fuente: elaboración propia con base en Adjust, 2022



**El uso de estos modelos se vincula directamente con decisiones estratégicas en adquisición de usuarios. Al estimar el valor futuro esperado, los equipos pueden ajustar el nivel de inversión en campañas en función del retorno proyectado, estableciendo relaciones más precisas entre *LTV* y *CAC* (costo de adquisición). Este enfoque permite priorizar fuentes de tráfico o segmentos que presentan mayor potencial de rentabilidad, optimizando la eficiencia del gasto publicitario.**

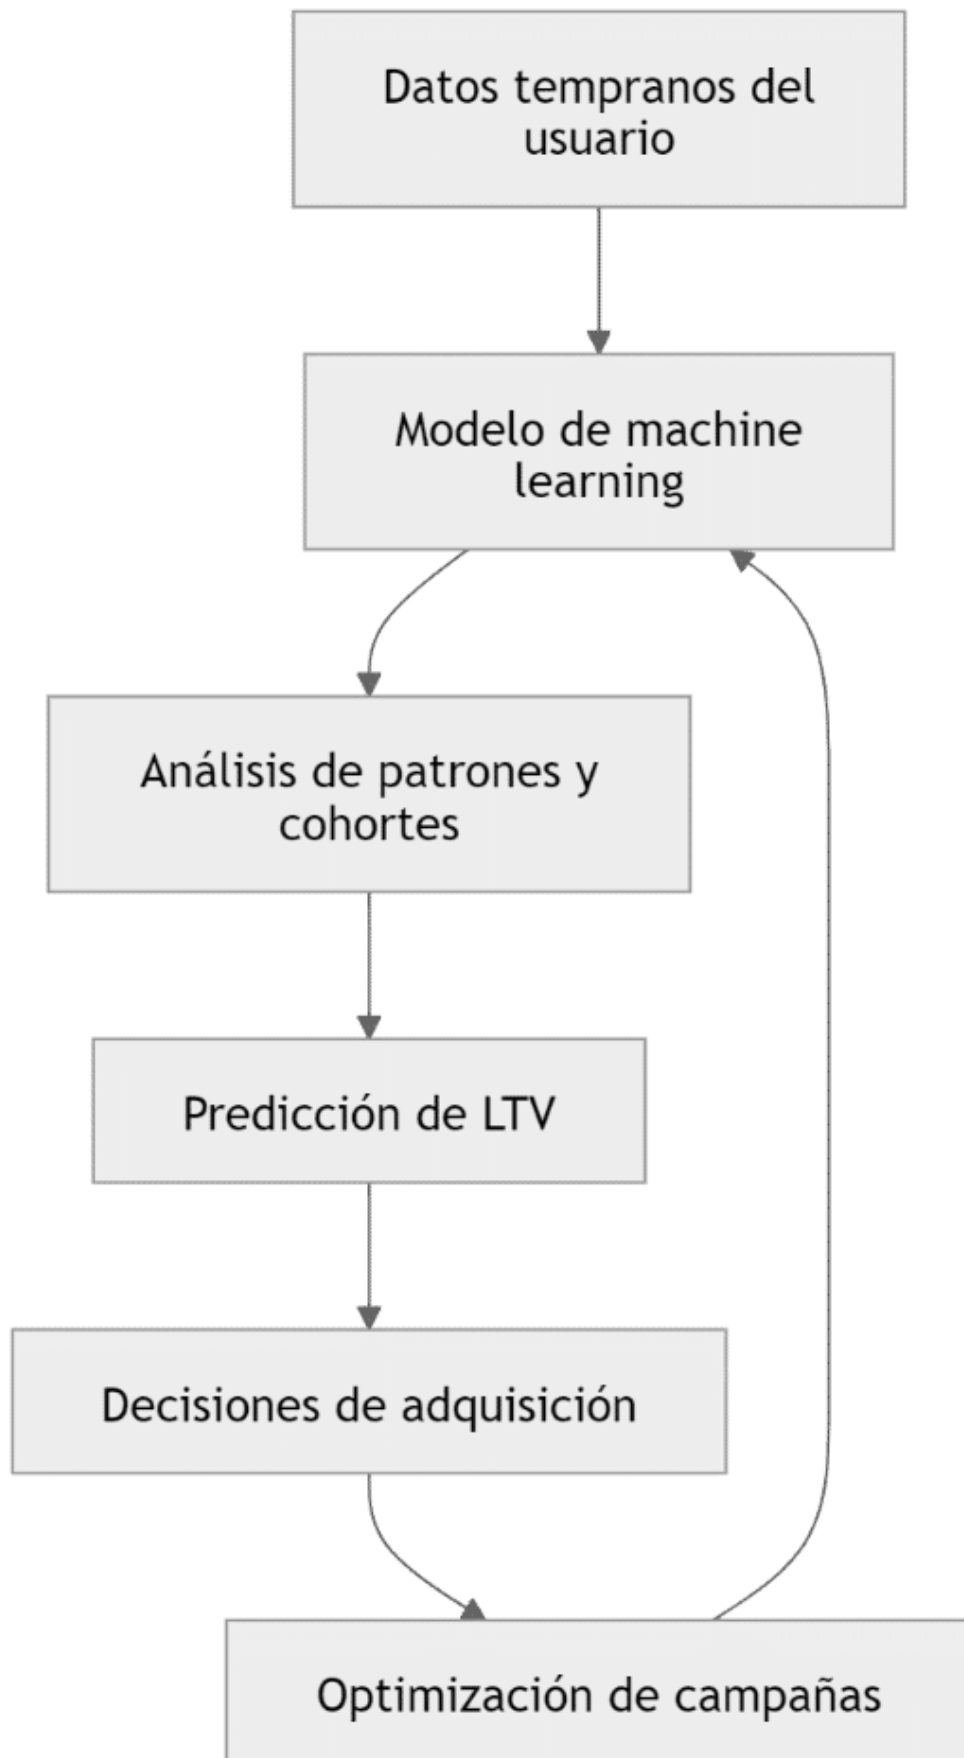
Asimismo, los modelos de *predictive LTV* permiten escalar campañas de manera controlada, ya que brindan información temprana sobre el rendimiento esperado. En lugar de esperar resultados consolidados a largo plazo, los equipos pueden identificar rápidamente qué campañas presentan mejores perspectivas y aumentar su inversión de forma progresiva. Esta lógica de escalamiento se apoya en la capacidad de los modelos para detectar patrones y relaciones entre variables que no resultan evidentes mediante análisis tradicionales.

En términos analíticos, estos modelos funcionan a partir del procesamiento de grandes volúmenes de datos enviados a algoritmos de aprendizaje automático, que eliminan ruido, identifican correlaciones y construyen predicciones sobre el

comportamiento futuro de los usuarios. Este proceso permite transformar datos fragmentados en información accionable, fortaleciendo la capacidad de anticipación en la toma de decisiones.

A partir de esta lógica, el *predictive LTV* se integra dentro de un enfoque más amplio de **optimización** y **personalización**, donde las decisiones de marketing se basan en probabilidades y no únicamente en resultados observados. Esto permite operar en contextos dinámicos, donde la información disponible es parcial, pero suficiente para construir modelos que orienten la acción.

## **Figura 2. Flujo de modelado de *predictive LTV***



A partir de este flujo, se observa cómo la predicción del valor del usuario se construye como un proceso iterativo, donde cada nuevo dato alimenta y mejora el modelo. Este mecanismo permite ajustar las decisiones de marketing de manera continua, integrando aprendizaje acumulado en cada ciclo de análisis.

En el ejercicio profesional, esta capacidad de anticipación habilita una gestión más eficiente del presupuesto y una mayor precisión en la segmentación de audiencias. Equipos que operan en entornos *mobile* pueden priorizar usuarios con mayor valor esperado, optimizar sus campañas desde etapas iniciales y sostener estrategias basadas en automatización, predicción y uso intensivo de datos.

## **Variables predictivas del LTV y su traducción en decisiones de inversión**

La estimación del *predictive LTV* en etapas tempranas se construye a partir de un conjunto de variables que permiten anticipar el valor futuro de un usuario antes de que complete su ciclo de vida dentro de la aplicación. Estas variables se vinculan principalmente con el comportamiento observado en los

primeros momentos de interacción, lo que habilita la construcción de modelos de **analítica predictiva** capaces de proyectar resultados a largo plazo. Según Wetzler (2022), los modelos de aprendizaje automático procesan grandes volúmenes de datos iniciales para identificar correlaciones entre acciones tempranas y monetización futura, lo que permite realizar estimaciones incluso cuando la información es parcial o se encuentra anonimizada.

El comportamiento temprano del usuario adquiere un papel central. Acciones como la frecuencia de uso en las primeras 24 horas, la profundidad de navegación o la interacción con funcionalidades específicas funcionan como señales que permiten inferir niveles de interés y compromiso. Estas señales se complementan con indicadores de **retención**, que reflejan la capacidad de la aplicación para sostener la relación con el usuario en el tiempo. A su vez, los primeros eventos de **monetización**, aunque sean incipientes, aportan información relevante sobre la propensión a generar ingresos, permitiendo clasificar usuarios en función de su potencial económico.

### **Tabla 3. Variables predictivas del LTV en etapas tempranas**

Variable	Tipo de dato	Indicador predictivo	Aplicación analítica
Comportamiento inicial	Eventos in-app	Nivel de interacción temprana	Identificación de interés del usuario
Retención temprana	Frecuencia de uso	Probabilidad de permanencia	Proyección de ciclo de vida
Monetización inicial	Compras o ingresos tempranos	Propensión a generar ingresos	Clasificación por valor potencial
Datos de cohorte	Agrupación de usuarios	Similitud con patrones históricos	Extrapolación de comportamiento futuro

Fuente: elaboración propia con base en Adjust, 2022

A partir de la integración de estas variables, los modelos de *machine learning* construyen estimaciones del valor futuro que permiten tomar decisiones sin esperar a que el usuario complete su recorrido. Este enfoque resulta particularmente relevante en contextos donde la información disponible se limita a ventanas temporales reducidas, como ocurre en entornos regulados por políticas

**de privacidad. En estos casos, la capacidad de inferir valor a partir de datos tempranos permite sostener procesos de optimización sin depender de mediciones completas.**

En el plano estratégico, estas estimaciones se traducen directamente en decisiones de inversión. La relación entre *LTV* y *CAC* (costo de adquisición) funciona como un criterio para determinar cuánto invertir en la captación de usuarios. Cuando el valor predictivo estimado supera el costo de adquisición, se habilita el escalamiento de campañas; en cambio, cuando el valor esperado es bajo, se ajustan o detienen las inversiones. Este enfoque permite gestionar el presupuesto de manera más eficiente, orientándolo hacia segmentos con mayor potencial de retorno.

Asimismo, el uso del *predictive LTV* permite priorizar fuentes de tráfico y canales de adquisición en función de su rendimiento esperado. En lugar de evaluar campañas únicamente por métricas inmediatas, como instalaciones o clics, los equipos pueden analizar el valor proyectado de los usuarios adquiridos. Esto transforma la lógica de optimización, desplazando el foco desde indicadores de corto plazo hacia métricas de valor a largo plazo, alineadas con los objetivos de negocio.

**Tabla 4. Traducción del *predictive LTV* en decisiones de inversión**

Variable analizada	Interpretación del modelo	Decisión de inversión	Impacto en marketing mobile
Alto LTV predictivo	Usuario con alto potencial de ingresos	Incrementar inversión en adquisición	Escalamiento de campañas
Bajo LTV predictivo	Usuario con bajo retorno esperado	Reducir o pausar inversión	Optimización de presupuesto
Retención elevada	Alta probabilidad de permanencia	Reforzar estrategias de fidelización	Mejora del engagement
Cohortes de alto valor	Segmentos con patrones positivos	Priorizar canales similares	Mejora en segmentación

Fuente: elaboración propia con base en Adjust, 2022

**En términos operativos, esta lógica permite tomar decisiones en etapas iniciales del ciclo de vida del usuario,**

**reduciendo la incertidumbre y acelerando los procesos de optimización. Equipos que gestionan campañas mobile pueden redistribuir presupuestos, ajustar segmentaciones y redefinir estrategias en función de predicciones tempranas, integrando la automatización y la predicción dentro del flujo de trabajo cotidiano.**

De este modo, el uso de variables predictivas del LTV no solo permite estimar el valor futuro del usuario, sino también estructurar decisiones de inversión más precisas, alineadas con objetivos de rentabilidad y crecimiento sostenido. La articulación entre datos tempranos, modelos predictivos y decisiones estratégicas configura un enfoque donde la información se convierte en un insumo directo para la acción.

**CONTINUAR**

## 2. Personalización y toma de decisiones basada en IA

---

En los entornos actuales de *mobile marketing*, la interacción con los usuarios se desarrolla en contextos altamente dinámicos, donde cada punto de contacto puede influir en la continuidad del vínculo con la aplicación. En este escenario, las decisiones vinculadas a qué contenido mostrar, en qué momento hacerlo y a través de qué canal, se apoyan cada vez más en sistemas de **inteligencia artificial** capaces de procesar datos en tiempo real. A partir de lo desarrollado en la unidad anterior —donde se abordaron modelos de optimización y predicción como el *predictive LTV*—, en este bloque se profundiza en cómo esos datos y modelos se traducen en experiencias personalizadas y en decisiones operativas concretas.

En la práctica profesional, los equipos enfrentan situaciones donde múltiples usuarios interactúan de manera simultánea con

una aplicación, pero presentan comportamientos, intereses y niveles de compromiso diferentes. En ese marco, la incorporación de sistemas de **personalización** permite adaptar las experiencias de uso en función de patrones detectados a partir de datos históricos y señales en tiempo real. Este enfoque supera las lógicas tradicionales de segmentación estática, ya que permite intervenir sobre la experiencia del usuario en función de su comportamiento específico y no únicamente de su pertenencia a un grupo predefinido.

A su vez, la integración de modelos de *machine learning* en sistemas de recomendación y orquestación de experiencias habilita nuevas formas de gestionar el *engagement*. Estos sistemas analizan grandes volúmenes de información para identificar relaciones entre usuarios, contenidos y contextos de uso, lo que permite anticipar qué acciones pueden resultar más relevantes en cada situación. De este modo, la toma de decisiones deja de estar basada exclusivamente en reglas generales y se apoya en modelos que aprenden de manera continua, ajustando sus respuestas a medida que se incorporan nuevos datos.

En este contexto, la personalización se articula con la toma de decisiones basada en datos, configurando un entorno donde cada interacción puede ser optimizada en función de objetivos específicos, como la retención, la conversión o el incremento del

valor del usuario. A lo largo de esta unidad se abordarán los sistemas de recomendación y las estrategias de personalización impulsadas por IA, analizando cómo se implementan en aplicaciones *mobile* y cómo impactan en métricas de **engagement**, **retención** y eficiencia operativa.

## Sistemas de recomendación en aplicaciones *mobile*

Los sistemas de recomendación, también conocidos como *recommendation engines*, constituyen una de las aplicaciones más extendidas de la **inteligencia artificial** en entornos *mobile*. Estos sistemas utilizan algoritmos de **machine learning** y análisis de datos para sugerir contenidos, productos o servicios en función del comportamiento de los usuarios. Según Caballar y Stryker (s.f.), los motores de recomendación identifican patrones en grandes volúmenes de datos para ofrecer sugerencias relevantes, facilitando el descubrimiento de opciones que el usuario no hubiera encontrado por sí mismo.

**En términos operativos, estos sistemas se apoyan en la recopilación y procesamiento de distintos tipos de datos. Por un lado, se consideran datos explícitos, como**

**valoraciones o preferencias declaradas; por otro, datos implícitos, como clics, historial de navegación o tiempo de permanencia. Esta combinación permite construir perfiles dinámicos que reflejan los intereses del usuario y habilitan procesos de personalización en tiempo real. En aplicaciones *mobile*, esta capacidad se traduce en recomendaciones dentro de feeds, sugerencias de productos o contenidos destacados que se ajustan continuamente al comportamiento observado.**

A partir de estos datos, los sistemas de recomendación siguen una lógica estructurada que integra almacenamiento, análisis, filtrado y refinamiento. Durante la fase de análisis, los modelos identifican correlaciones y relaciones entre usuarios y elementos, lo que permite anticipar qué contenidos tienen mayor probabilidad de generar interacción. Este proceso se complementa con mecanismos de filtrado que priorizan las opciones más relevantes, optimizando la experiencia del usuario y aumentando las probabilidades de conversión.

En el ejercicio profesional, estos sistemas se aplican en múltiples contextos: desde plataformas de *e-commerce* que sugieren productos complementarios, hasta aplicaciones de contenido que recomiendan videos, música o noticias. Este tipo de

implementación permite aumentar el nivel de **engagement** y mejorar indicadores como la retención y la conversión. De hecho, según datos citados por IBM, la personalización puede incrementar los ingresos entre un 5 % y un 15 %, lo que evidencia su impacto en los resultados de negocio.

**Tabla 5. Tipos de sistemas de recomendación**

Tipo de recomendador	Lógica de funcionamiento	Aplicación en mobile
Filtrado colaborativo	Basado en similitud entre usuarios	Recomendaciones de productos o contenido
Filtrado basado en contenido	Basado en características de los ítems	Sugerencias similares a intereses previos
Sistema híbrido	Combinación de ambos enfoques	Plataformas complejas como <i>streaming</i>

Fuente: elaboración propia con base en IBM, s.f.



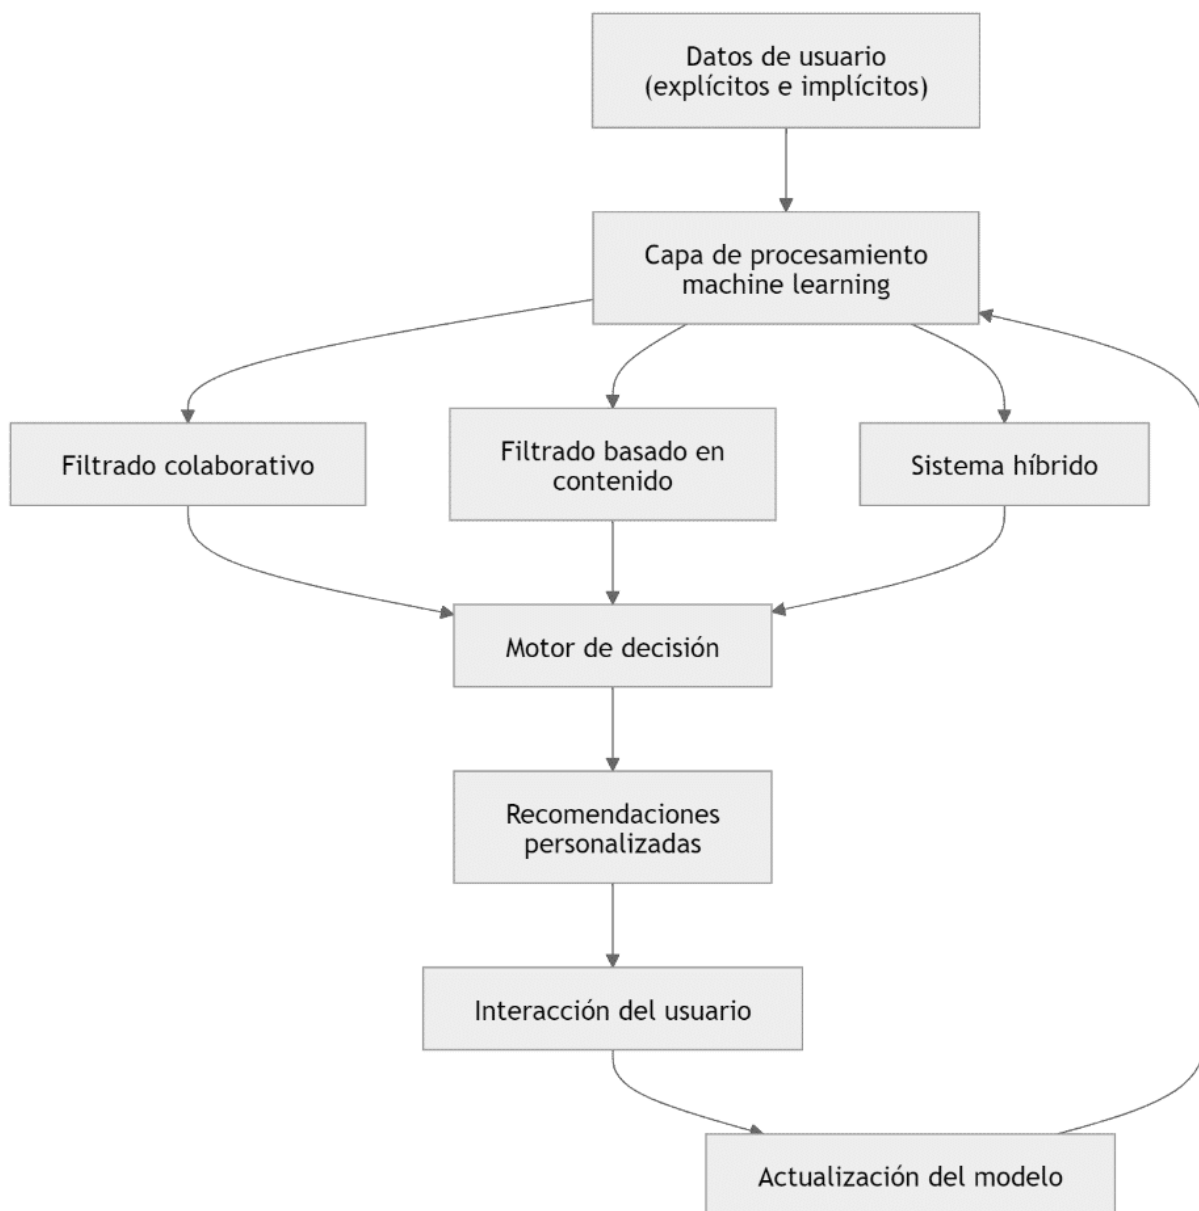
**El filtrado colaborativo opera a partir de la comparación entre usuarios con comportamientos similares, asumiendo que aquellos con preferencias cercanas tenderán a interesarse por los mismos contenidos. Este enfoque resulta efectivo en plataformas con grandes volúmenes de interacción, ya que permite detectar patrones colectivos. Por su parte, el filtrado basado en contenido se centra en las características de los elementos consumidos, recomendando opciones similares a partir de atributos compartidos, como categorías o etiquetas.**

El enfoque híbrido combina ambos modelos, integrando datos de comportamiento y características de los contenidos para mejorar la precisión de las recomendaciones. Este tipo de sistema permite superar limitaciones específicas de cada enfoque individual, como el problema de arranque en frío en el filtrado colaborativo. En aplicaciones mobile, esta combinación resulta particularmente útil para ofrecer recomendaciones más robustas en contextos donde los datos pueden ser parciales o evolucionar rápidamente.

Desde una perspectiva analítica, estos sistemas funcionan como un circuito continuo donde los datos del usuario alimentan modelos que generan recomendaciones, y estas interacciones vuelven a alimentar el sistema. Este proceso iterativo permite

mejorar progresivamente la calidad de las sugerencias, integrando nuevos datos en cada ciclo de interacción.

**Figura 3. Arquitectura funcional de un sistema de recomendación**



A partir de esta arquitectura, los sistemas de recomendación operan como estructuras integradas donde cada capa cumple una función específica dentro del proceso de generación de sugerencias. La combinación entre la capa de datos, los modelos de *machine learning* y los distintos enfoques de filtrado permite construir recomendaciones que no dependen de una única lógica, sino de la articulación entre múltiples métodos analíticos. De este modo, la decisión final sobre qué contenido mostrar se produce en un punto de convergencia donde se sintetizan patrones de comportamiento, características de los ítems y relaciones entre usuarios.

La interacción del usuario con las recomendaciones no se limita a una respuesta final del sistema, sino que constituye un insumo que retroalimenta toda la arquitectura. Cada clic, visualización o compra impacta en la actualización del modelo, ajustando el peso relativo de los distintos tipos de filtrado y refinando la precisión de las sugerencias. Esta dinámica permite que el sistema evolucione de manera continua, integrando nuevos datos dentro de una lógica de **personalización** progresiva.

Desde una perspectiva aplicada al *mobile marketing*, esta estructura habilita estrategias donde la toma de decisiones se

distribuye entre distintos niveles del sistema. Por ejemplo, una aplicación puede combinar recomendaciones basadas en comportamiento colectivo (*collaborative filtering*) con sugerencias centradas en atributos del contenido (*content-based*), ajustando automáticamente la relevancia de cada enfoque según el contexto de uso. Esta flexibilidad mejora la capacidad del sistema para adaptarse a distintos escenarios de interacción.

**En consecuencia, los sistemas de recomendación se consolidan como herramientas que articulan datos, modelos predictivos y decisiones operativas dentro de una misma arquitectura. Esta integración permite sostener experiencias dinámicas, donde cada recomendación se construye a partir de múltiples fuentes de información y se ajusta en función del comportamiento del usuario, contribuyendo a mejorar indicadores como el engagement, la retención y la conversión.**

**Estrategias de personalización  
impulsadas por IA**

Las estrategias de personalización impulsadas por IA, conocidas como *AI-powered personalization*, consisten en el uso de sistemas de **machine learning** y análisis de datos para adaptar las interacciones con los usuarios en función de sus características, comportamientos y contextos. Este enfoque permite construir experiencias diferenciadas en tiempo real, integrando información proveniente de múltiples fuentes, como datos demográficos, patrones de navegación y hábitos de consumo. Según Goldstein (2025), la personalización basada en IA analiza estos datos para ofrecer experiencias relevantes que incrementan la satisfacción, el *engagement* y las conversiones.

En el ámbito del *mobile marketing*, esta lógica implica una transformación respecto de la segmentación tradicional. Mientras que los enfoques clásicos agrupan usuarios en categorías estáticas, la personalización basada en IA construye perfiles dinámicos que se actualizan de manera continua. Este proceso se apoya en la integración de datos en plataformas centralizadas, como las *Customer Data Platforms (CDP)*, que permiten consolidar información proveniente de distintos canales y construir una visión unificada del usuario. A partir de esta base, los sistemas pueden anticipar necesidades y ajustar las interacciones en función del comportamiento observado.

En términos operativos, la personalización se materializa a través de múltiples puntos de contacto dentro del ecosistema *mobile*. Esto incluye desde recomendaciones de productos hasta mensajes *push*, contenidos in-app y campañas de email marketing adaptadas a cada usuario. La capacidad de orquestar estas interacciones de manera coordinada permite construir recorridos personalizados que acompañan al usuario a lo largo de su ciclo de vida, mejorando la coherencia de la experiencia y optimizando los resultados de negocio.

Este enfoque también se vincula con la capacidad de los sistemas de adaptarse en tiempo real. A medida que los usuarios interactúan con la aplicación, los modelos ajustan sus predicciones y modifican las recomendaciones o contenidos mostrados. Este proceso de actualización continua permite sostener una lógica de **personalización**, donde cada interacción contribuye a refinar la experiencia del usuario y a mejorar la precisión de las decisiones.

**Tabla 6. Tipos de personalización impulsada por IA en *mobile marketing***

Tipo de personalización	Descripción	Aplicación en mobile
Personalización de contenido	Adaptación de mensajes y elementos visuales	Feeds dinámicos, banners personalizados
Recomendaciones en tiempo real	Sugerencias basadas en comportamiento inmediato	Productos o contenidos sugeridos
Personalización de campañas	Ajuste de mensajes según perfil del usuario	<i>Push notifications</i> , emails segmentados
Personalización de precios	Ajuste dinámico según demanda y comportamiento	Ofertas y descuentos personalizados

Fuente: elaboración propia con base en Goldstein, 2025

**La implementación de estas estrategias requiere una infraestructura capaz de gestionar grandes volúmenes de datos y procesarlos de manera eficiente. En este sentido, herramientas como las CDP y los sistemas de gestión de contenido desacoplados (*headless CMS*) cumplen un rol central. Estas tecnologías permiten distribuir contenido personalizado a través de múltiples canales de manera**

## consistente, integrando la lógica de decisión de la IA con la entrega efectiva de las experiencias al usuario.

A su vez, la personalización impulsada por IA tiene un impacto directo en indicadores de desempeño. Según el documento analizado, este tipo de estrategias permite incrementar las tasas de conversión, mejorar la retención de usuarios y optimizar los costos operativos mediante la segmentación precisa de audiencias. Además, la capacidad de ofrecer experiencias relevantes reduce la fricción en la interacción y fortalece la relación entre el usuario y la aplicación.

Desde una perspectiva analítica, estas estrategias se apoyan en la integración de distintos tipos de datos, que permiten construir modelos más completos del comportamiento del usuario. La combinación de datos demográficos, comportamentales y contextuales habilita una comprensión más profunda de las necesidades y preferencias, lo que se traduce en decisiones más ajustadas a cada situación.

En el ejercicio profesional, esta lógica permite diseñar estrategias donde la comunicación y el contenido se adaptan de manera continua, integrando la **automatización**, la **predicción** y el análisis de datos dentro del flujo de trabajo. Esto habilita

intervenciones más precisas y oportunas, alineadas con los objetivos de negocio y con las expectativas del usuario.

**Tabla 7. Tipos de datos utilizados en personalización con IA**

Tipo de dato	Descripción	Uso en personalización
Datos demográficos	Edad, género, ubicación	Segmentación inicial
Datos comportamentales	Navegación, clics, interacción	Ajuste de contenido en tiempo real
Datos transaccionales	Historial de compras	Recomendaciones y ofertas personalizadas
Datos contextuales	Ubicación, momento del día	Adaptación situacional
Datos de interacción	Tiempo de uso, feedback	Optimización de experiencia

Fuente: elaboración propia con base en Goldstein, 2025

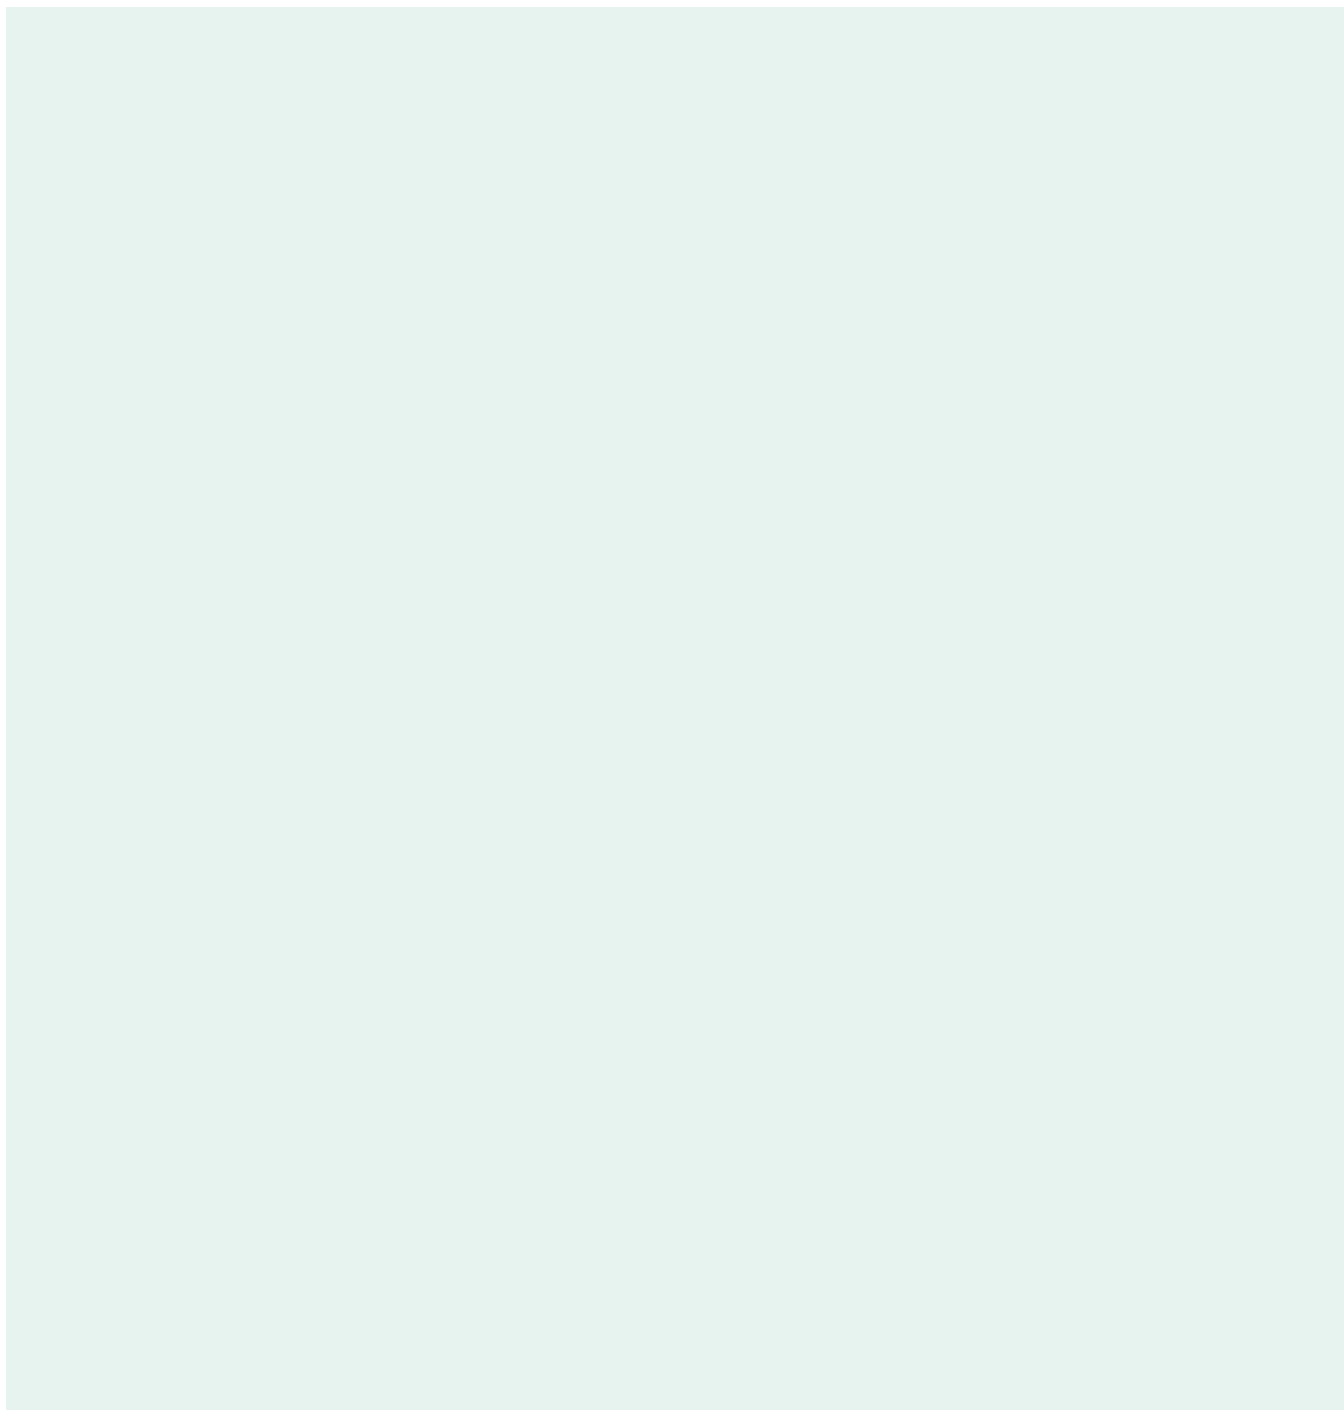
En este contexto, las estrategias de personalización impulsadas por IA se consolidan como un componente central en la toma de

decisiones dentro del *mobile marketing*. La capacidad de adaptar contenidos, mensajes y ofertas en función de datos dinámicos permite construir experiencias más relevantes, mejorar el ***engagement*** y optimizar la relación entre inversión y resultados. De este modo, la personalización se integra como una práctica operativa que articula datos, tecnología y estrategia dentro de un mismo sistema de decisión.

CONTINUAR

# Referencias

---



**Equipo IEBS.** (2025, diciembre 17). *Qué es la inteligencia artificial aplicada al marketing digital (y por qué ya no es “opcional”)*. IEBS Business School. <https://www.iebschool.com/hub/inteligencia-artificial-marketing-digital/>

**Wetzler, T.** (2022, marzo 14). *Cómo calcular el LTV sin tener acceso al IDFA: resolver la necesidad del análisis predictivo*. Adjust. <https://www.adjust.com/es/blog/predictive-analytics-and-ltv-post-idfa/>

**Caballar, R. D., & Stryker, C.** (s.f.). *¿Qué es un motor de recomendación?* IBM. <https://www.ibm.com/es-es/think/topics/recommendation-engine>

**Goldstein, B.** (2025, diciembre 15). *How AI-powered personalization enhances customer experience*. Contentstack. <https://www.contentstack.com/blog/tech-talk/how-ai-powered-personalization-enhances-customer-experience>

CONTINUAR