



DOI: <https://doi.org/10.23857/dc.v11i4.4613>

Ciencias Técnicas y Aplicadas
Artículo de Investigación

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

Artificial intelligence explainable in digital analytics: transparency in predictive consumption models

Inteligência artificial explicável em análises digitais: transparência em modelos preditivos de consumo

Doménica Patricia Lalama Freire ¹
domenica.lalama@epoch.edu.ec
<https://orcid.org/0009-0000-5279-885X>

Correspondencia: domenica.lalama@epoch.edu.ec

*Recibido: 31 de octubre de 2025 *Aceptado: 28 de noviembre de 2025 * Publicado: 08 de diciembre de 2025

I. Licenciada en Marketing, Maestría en Marketing con Mención en Marketing Digital, Docente de la Facultad de Administración de Empresas, ESPOCH, Riobamba, Ecuador.

Resumen

Este estudio aborda la Inteligencia Artificial explicable (XAI) aplicada a la Analítica Digital del comportamiento de consumo, enfatizando la urgencia corporativa de asegurar transparencia, auditabilidad y confiabilidad en los modelos predictivos utilizados para la toma de decisiones estratégicas. El objetivo central es evaluar cómo los mecanismos de explicabilidad fortalecen la interpretación de los patrones de consumo, reducen la opacidad algorítmica y optimizan la eficiencia en la asignación de recursos de marketing. Desde una perspectiva teórica, se fundamenta en los enfoques contemporáneos de machine learning interpretativo, modelos pos-hoc y marcos de gobernanza algorítmica. Se destacan conceptos clave como interpretabilidad intrínseca, atribución de características, sesgo algorítmico, responsabilidad digital, así como técnicas ampliamente aceptadas en XAI, entre ellas SHAP, LIME, modelos árbol-transparente y visualizaciones de sensibilidad. La revisión conceptual establece que la transparencia no solo es un requisito ético, sino un activo estratégico para ecosistemas empresariales intensivos en datos. Los resultados más relevantes evidencian que los modelos predictivos explicables incrementan la precisión operacional del análisis de consumo en entornos complejos, facilitan la comprensión ejecutiva de los drivers del comportamiento y permiten validar la coherencia entre los datos utilizados y las decisiones comerciales derivadas. Además, se identifican mejoras sustantivas en la detección temprana de anomalías, la mitigación del sesgo y la construcción de confianza entre stakeholders internos y externos. En conclusión, la incorporación de XAI en la Analítica Digital no solo potencia el rendimiento de los modelos, sino que consolida un enfoque de toma de decisiones responsable, alineado con estándares emergentes de gobernanza tecnológica y competitividad empresarial.

Palabras clave: Inteligencia artificial explicable (XAI); analítica digital; modelos predictivos de consumo; transparencia algorítmica; interpretabilidad de datos.

Abstract

This study addresses explainable artificial intelligence (XAI) applied to digital analytics of consumer behavior, emphasizing the corporate urgency of ensuring transparency, auditability, and reliability in the predictive models used for strategic decision-making. The central objective is to evaluate how explainability mechanisms strengthen the interpretation of consumption patterns, reduce algorithmic opacity, and optimize the efficiency of marketing resource allocation. From a theoretical perspective, it is grounded in contemporary approaches to interpretive machine learning, post-hoc models, and

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

algorithmic governance frameworks. Key concepts such as intrinsic interpretability, feature attribution, algorithmic bias, and digital accountability are highlighted, as well as widely accepted XAI techniques, including SHAP, LIME, transparent-tree models, and sensitivity visualizations. The conceptual review establishes that transparency is not only an ethical requirement but also a strategic asset for data-intensive business ecosystems. The most relevant results demonstrate that explainable predictive models increase the operational accuracy of consumer analysis in complex environments, facilitate executive understanding of behavioral drivers, and allow for validation of the consistency between the data used and the resulting business decisions. Furthermore, substantial improvements are identified in the early detection of anomalies, bias mitigation, and the building of trust among internal and external stakeholders. In conclusion, the incorporation of XAI into Digital Analytics not only enhances model performance but also consolidates a responsible decision-making approach, aligned with emerging standards of technology governance and business competitiveness.

Keywords: Explainable artificial intelligence (XAI); digital analytics; consumer predictive models; algorithmic transparency; data interpretability.

Resumo

Este estudo aborda a inteligência artificial explicável (XAI) aplicada à análise digital do comportamento do consumidor, enfatizando a urgência corporativa de garantir transparência, auditabilidade e confiabilidade nos modelos preditivos utilizados para a tomada de decisões estratégicas. O objetivo central é avaliar como os mecanismos de explicabilidade fortalecem a interpretação dos padrões de consumo, reduzem a opacidade algorítmica e otimizam a eficiência da alocação de recursos de marketing. Do ponto de vista teórico, o estudo se fundamenta em abordagens contemporâneas de aprendizado de máquina interpretativo, modelos post-hoc e estruturas de governança algorítmica. Conceitos-chave como interpretabilidade intrínseca, atribuição de características, viés algorítmico e responsabilidade digital são destacados, assim como técnicas de XAI amplamente aceitas, incluindo SHAP, LIME, modelos de árvore transparente e visualizações de sensibilidade. A revisão conceitual estabelece que a transparência não é apenas uma exigência ética, mas também um ativo estratégico para ecossistemas de negócios com uso intensivo de dados. Os resultados mais relevantes demonstram que modelos preditivos explicáveis aumentam a precisão operacional da análise do consumidor em ambientes complexos, facilitam a compreensão dos executivos sobre os fatores comportamentais e permitem a validação da consistência entre os dados

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

utilizados e as decisões de negócios resultantes. Além disso, foram identificadas melhorias substanciais na detecção precoce de anomalias, na mitigação de vieses e na construção de confiança entre as partes interessadas internas e externas. Em conclusão, a incorporação da Inteligência Artificial Explicável (XAI) na Análise Digital não apenas aprimora o desempenho do modelo, mas também consolida uma abordagem responsável para a tomada de decisões, alinhada aos padrões emergentes de governança de tecnologia e competitividade empresarial.

Palavras-chave: Inteligencia artificial explicável (XAI); análise digital; modelos predictivos do consumidor; transparéncia algorítmica; interpretabilidadade de dados.

Introducción

La creciente adopción de modelos predictivos en la analítica digital ha transformado la forma en que las organizaciones interpretan el comportamiento de consumo; se reconoce que la Inteligencia Artificial aporta ventajas competitivas al anticipar patrones, optimizar recursos y personalizar experiencias, pero también se acepta que sus procesos internos suelen operar como “cajas negras”. Esta falta de claridad genera incertidumbre sobre la validez, el sesgo y la coherencia de los resultados, especialmente cuando las decisiones derivadas tienen impacto financiero y reputacional.

El problema aún no resuelto radica en la insuficiente transparencia de los algoritmos que sustentan la predicción del consumo, lo que limita la capacidad de auditar, justificar o corregir decisiones automatizadas; de esta situación surge la pregunta de investigación: ¿cómo contribuyen los enfoques de Inteligencia Artificial explicable a mejorar la transparencia y confiabilidad de los modelos predictivos aplicados al análisis digital del consumo?

La hipótesis plantea que la incorporación sistemática de técnicas de explicabilidad fortalece la interpretabilidad de los modelos, reduce el sesgo algorítmico y aumenta la eficiencia en la toma de decisiones estratégicas basadas en datos. En consecuencia, la meta del estudio es demostrar el valor operativo y ético de la XAI en entornos digitales altamente dependientes de modelos predictivos.

Los objetivos se orientan a evaluar el desempeño de técnicas de explicabilidad, identificar los factores que influyen en la transparencia de los modelos y proponer lineamientos que integren XAI como práctica estándar en la analítica digital del consumo. Esta investigación se realiza con el propósito de responder a la necesidad empresarial de decisiones más confiables, responsables y estratégicamente sustentadas, motivando así al lector a profundizar en los hallazgos que se presentan a continuación.

Desarrollo

La literatura sobre explicabilidad en inteligencia artificial (XAI) constituye la base conceptual para entender la necesidad de transparencia en modelos predictivos aplicados al comportamiento de consumo. Estudios fundacionales introducen técnicas post-hoc y locales para explicar predicciones individuales, por ejemplo, LIME que permiten descomponer la contribución de las variables a una decisión puntual y facilitar la verificación humana de resultados (Ribeiro, Singh & Guestrin, 2016). Paralelamente, el desarrollo de marcos matemáticos como SHAP establece una familia unificada de medidas aditivas de importancia de variables basada en valores de Shapley, aportando propiedades axiomáticas útiles para auditoría y comparación entre métodos. Estos aportes metodológicos configuran las herramientas operativas que sustentan la explicabilidad práctica en analítica digital. (Ribeiro et al., 2016; Lundberg & Lee, 2017).

En la esfera teórica y epistemológica, autores como Doshi-Velez y Kim (2017) y Lipton (2016) problematizan la noción misma de “interpretabilidad”: distinguen entre interpretabilidad intrínseca (modelos transparentes por diseño) y explicaciones post-hoc, y solicitan métricas rigurosas para evaluar cuándo la explicabilidad es necesaria y cómo medir su efectividad. Esta discusión es clave para la analítica del consumo porque obliga a definir objetivos de explicabilidad (por ejemplo, confianza del decisor, cumplimiento regulatorio, detección de sesgos) y a seleccionar técnicas alineadas con esos fines, en lugar de adoptar enfoques XAI por moda. (Doshi-Velez & Kim, 2017; Lipton, 2016).

Revisiones comprehensivas y taxonómicas recientes consolidan avances y desafíos: Arrieta et al. (2020) sintetizan conceptos, taxonomías y límites de XAI y destacan retos prácticos fidelidad vs. interpretabilidad, evaluación humana de explicaciones y escalabilidad que son directamente relevantes para despliegues comerciales de modelos de consumo. Complementariamente, Molnar (2020) ofrece un compendio aplicado de técnicas (modelos transparentes, importancia de características, explicaciones locales y globales) orientadas a praxis, lo que facilita la transferencia de métodos XAI a entornos de marketing y analítica digital. Estas revisiones sostienen que, si bien existe surtido técnico, la adopción exige marcos de gobernanza y métricas estandarizadas. (Arrieta et al., 2020; Molnar, 2020).

En el ámbito aplicado marketing y analítica de consumo emergen preocupaciones sobre sesgo algorítmico, privacidad y aceptación del consumidor. Investigaciones sobre sesgo en modelos de marketing y decisiones algorítmicas muestran que la falta de transparencia dificulta la detección de

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

discriminaciones y erosiona la confianza de clientes y stakeholders, lo que puede traducirse en riesgos reputacionales y regulatorios. Por ello, trabajos recientes proponen marcos para identificar fuentes de sesgo y prácticas de gobernanza que integren XAI como componente de control y explicación en sistemas predictivos comerciales (Akter, 2022; Lepri et al., 2018). Estos antecedentes subrayan que la explicabilidad no es solo una cuestión técnica sino un requerimiento organizacional y regulatorio en entornos de consumo.

A partir de estos antecedentes se derivan líneas de investigación y vacíos empíricos pertinentes para el artículo:

1. Evaluar comparativamente la fidelidad y utilidad operacional de técnicas XAI (LIME, SHAP y métodos basados en árboles transparentes) en problemas reales de predicción de consumo;
2. Medir el impacto de explicaciones en la detección de sesgos y en la toma de decisiones gerenciales; y
3. Articular marcos de gobernanza que traduzcan explicabilidad técnica en cumplimiento, auditoría y reporting interno. La convergencia de propuestas metodológicas y preocupaciones regulatorias configura el marco conceptual que justifica y orienta el presente estudio.

Marco Conceptual

1. Naturaleza y justificación de la XAI

- **Complejidad y opacidad de los modelos de IA modernos**

El desarrollo acelerado del machine learning y, especialmente, del deep learning ha permitido construir modelos predictivos capaces de identificar patrones complejos con una precisión sin precedentes. Sin embargo, este avance ha venido acompañado de un incremento significativo en la opacidad de dichos modelos, particularmente en redes neuronales profundas, modelos de ensembles y arquitecturas híbridas, que dificultan la trazabilidad del proceso de decisión interna (Castelvecchi, 2016; Lipton, 2018). Esta naturaleza de “caja negra” genera desafíos críticos en entornos donde las decisiones tienen implicaciones éticas, económicas o regulatorias, como el marketing digital, el consumo masivo y la analítica basada en comportamiento del usuario (Burrell, 2016). Ante este contexto, la imposibilidad de comprender cómo el algoritmo transforma las entradas en predicciones afecta la confianza, la responsabilidad y la auditabilidad del sistema.

• **El surgimiento de la XAI como respuesta técnica, ética y operativa**

La Inteligencia Artificial Explicable (XAI) surge como un campo destinado a enfrentar la falta de transparencia inherente a los modelos complejos, proporcionando métodos para interpretar, justificar y auditar decisiones algorítmicas (Gunning & Aha, 2019). Esta disciplina no solo responde a una necesidad técnica de comprensión del modelo, sino también a exigencias éticas, regulatorias y organizacionales relacionadas con la justicia algorítmica, la equidad y la gobernanza de sistemas autónomos (Doshi-Velez & Kim, 2017). En mercados orientados al consumidor, la XAI se ha consolidado como un componente estratégico que permite identificar sesgos, mejorar la confianza y garantizar la rendición de cuentas frente a usuarios, reguladores y stakeholders (Arrieta et al., 2020).

2. Clasificación de enfoques en XAI: interpretabilidad intrínseca vs. explicabilidad post-hoc

• **Interpretabilidad intrínseca (modelos transparentes por diseño)**

La interpretabilidad intrínseca se refiere al uso de modelos que, por su estructura matemática y lógica, permiten comprender directamente cómo se generan las predicciones. Modelos como regresiones lineales, árboles de decisión o reglas basadas en lógica ofrecen un acceso explícito a la relación entre variables y resultados (Molnar, 2022). Gracias a esta transparencia natural, los modelos “white-box” son especialmente valiosos en contextos donde la trazabilidad es un requisito regulatorio o donde los responsables de negocio requieren explicaciones claras para la toma de decisiones (Rudin, 2019). No obstante, estos enfoques presentan limitaciones en su capacidad para modelar interacciones no lineales complejas, reduciendo su aplicabilidad en entornos de analítica avanzada de consumo digital.

• **Explicabilidad post-hoc: métodos para “abrir” cajas negras**

Cuando los modelos intrínsecamente interpretables no alcanzan la precisión requerida, se recurre a técnicas post-hoc que generan explicaciones externas sin modificar la estructura algorítmica original (Guidotti et al., 2019). Estos métodos pueden ofrecer explicaciones locales centradas en casos individuales o explicaciones globales sobre el comportamiento general del modelo (Molnar, 2022). Aunque permiten combinar alto desempeño predictivo con cierto grado de interpretabilidad, presentan un trade-off importante: las explicaciones pueden ser aproximaciones parciales que no siempre reflejan con total fidelidad la lógica interna del modelo original (Ribeiro et al., 2016).

3. Principales técnicas XAI: mecánicas, ventajas y limitaciones

- **LIME (Local Interpretable Model-agnostic Explanations)**

LIME es un método post-hoc que aproxima el comportamiento del modelo complejo alrededor de una predicción específica mediante un modelo interpretable local, usualmente lineal (Ribeiro et al., 2016). Esta técnica permite identificar las características que influyen en una predicción individual, facilitando la justificación de decisiones algorítmicas ante auditorías o usuarios finales. Sin embargo, la estabilidad de las explicaciones puede verse afectada por la variabilidad inherente a la generación de muestras locales, lo que puede comprometer la consistencia entre explicaciones de instancias similares (Alvarez-Melis & Jaakkola, 2018).

- **SHAP (SHapley Additive exPlanations)**

SHAP se fundamenta en valores de Shapley provenientes de la teoría de juegos cooperativos, proporcionando explicaciones aditivas que asignan a cada característica su contribución a la predicción (Lundberg & Lee, 2017). Este método ofrece ventajas significativas en términos de consistencia y equidad, así como la posibilidad de análisis a nivel global y local, lo cual es especialmente útil en contextos de consumo digital donde se requiere identificar los drivers clave del comportamiento del cliente (Molnar, 2022). Su principal limitación radica en su alto costo computacional, especialmente para modelos con muchas variables o conjuntos de datos extensos (Chen et al., 2020).

- **Técnicas de saliencia y visualización en deep learning**

En modelos de deep learning aplicados a datos no estructurados, las técnicas de saliencia como Grad-CAM, LRP o guided backpropagation permiten identificar qué regiones de la entrada influyen más en la predicción (Selvaraju et al., 2017; Bach et al., 2015). Estas herramientas son fundamentales en análisis avanzados como visión computacional, procesamiento de lenguaje natural y analítica de consumo basada en datos heterogéneos. No obstante, las explicaciones generadas pueden ser ambiguas y no siempre garantizan una verdadera correspondencia con la lógica interna del modelo (Adebayo et al., 2018).

- **Modelos transparentes por diseño**

Los modelos transparentes, como árboles interpretables, reglas basadas en lógica o modelos lineales parciales, ofrecen un enfoque diferente al proporcionar interpretabilidad desde la estructura misma del modelo (Rudin, 2019). Son especialmente útiles en entornos donde los responsables de negocio o reguladores requieren total trazabilidad. Su limitación principal es su incapacidad para igualar la

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo
precisión de modelos complejos en tareas de alta dimensionalidad o alto nivel de no linealidad (Molnar, 2022).

4. Evaluación de explicaciones: métricas, calidad, fidelidad y robustez

- Necesidad de métricas objetivas y multidimensionales**

La proliferación de técnicas XAI ha impulsado la necesidad de establecer métricas robustas que permitan evaluar la calidad y utilidad de las explicaciones. Diversos estudios han propuesto marcos multidimensionales que incluyen fidelidad, estabilidad, coherencia, simplicidad y relevancia (Doshi-Velez & Kim, 2017; Zhou et al., 2021). La ausencia de métricas estandarizadas representa un desafío para la reproducibilidad y la comparabilidad entre métodos.

- Trade-offs entre exactitud y explicabilidad**

La tensión entre desempeño predictivo y explicabilidad es uno de los dilemas centrales en XAI. Modelos complejos suelen presentar mayor precisión, pero a costa de menor transparencia; en cambio, los modelos simples ofrecen interpretabilidad, pero pueden comprometer el rendimiento (Rudin, 2019). En entornos empresariales, este equilibrio debe evaluarse estratégicamente, considerando riesgos, regulaciones, costos y objetivos organizacionales (Arrieta et al., 2020).

- Evaluación práctica: usabilidad, contexto y requisitos regulatorios**

Además de las métricas técnicas, la efectividad de una explicación depende del contexto de aplicación, del perfil del usuario y de los requisitos regulatorios (Wang et al., 2019). En analítica digital, las explicaciones deben ser comprensibles para analistas, gerentes y consumidores, lo que requiere enfoques interactivos, adaptables y centrados en el usuario.

5. Gobernanza algorítmica, ética y responsabilidad

- Sesgo algorítmico y justicia**

Los sesgos algorítmicos pueden amplificar desigualdades en modelos utilizados para personalización, segmentación o pricing dinámico. La XAI permite detectar y mitigar estas dinámicas al hacer visibles las relaciones entre variables y decisiones (Barocas et al., 2019). Su inclusión es fundamental para garantizar equidad y responsabilidad en decisiones automatizadas.

- Transparencia, confianza y regulación**

La transparencia en modelos predictivos se ha convertido en un imperativo ético y regulatorio, impulsado por marcos como el GDPR o el AI Act de la Unión Europea (Wachter et al., 2017). La XAI fortalece la confianza de consumidores, facilita auditorías y reduce riesgos reputacionales, especialmente en sectores sensibles como finanzas, salud o consumo digital (Arrieta et al., 2020).

- **Gobernanza organizacional y cultura de datos**

La adopción efectiva de XAI requiere procesos de gobernanza que incluyan documentación, auditorías internas, monitoreo continuo y capacitación del personal (Morley et al., 2020). No se trata solo de técnicas, sino de una transformación cultural orientada a la transparencia y la responsabilidad.

6. Aplicaciones de XAI en Analítica Digital y Predicción de Consumo

- **Segmentación, predicción y personalización**

Los modelos predictivos aplicados a consumo digital permiten identificar patrones de comportamiento, anticipar compras y personalizar estrategias. La XAI potencia estos modelos proporcionando claridad sobre qué variables influyen en las predicciones, mejorando la calidad de decisiones y optimizando recursos (Kumar et al., 2021).

- **Auditoría y detección de anomalías**

La explicabilidad es clave para identificar fraudes, anomalías y comportamientos atípicos en entornos digitales, permitiendo auditar predicciones y justificar acciones ante reguladores o stakeholders internos (Carvalho et al., 2019). Este enfoque es esencial en plataformas de consumo masivo y comercio electrónico.

- **Transparencia hacia consumidores y stakeholders**

La XAI contribuye a la legitimidad y confianza de sistemas basados en IA al permitir que consumidores comprendan por qué reciben ciertas recomendaciones, precios o segmentaciones (Wachter et al., 2017). En mercados competitivos, la transparencia se convierte en un activo estratégico que fortalece la reputación organizacional.

Metodología

La investigación adopta un diseño metodológico mixto secuencial explicativo, que integra análisis cuantitativo y cualitativo con el propósito de evaluar el desempeño, la interpretabilidad y la transparencia de modelos predictivos aplicados al comportamiento de consumo en plataformas digitales. Este enfoque permite capturar tanto la eficiencia estadística de los algoritmos como la claridad cognitiva de sus explicaciones, en línea con recomendaciones metodológicas recientes en estudios de XAI (Molnar, 2022; Samek & Müller, 2019).

1. Enfoque y diseño de investigación

El estudio se fundamenta en un paradigma pragmático, centrado en resolver un problema aplicado de transparencia algorítmica. Se emplea un diseño explicativo cuyo objetivo es determinar cómo los

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

métodos de XAI contribuyen a mejorar la comprensión de los modelos de predicción de consumo y su impacto en la toma de decisiones estratégicas (Guidotti et al., 2018). El diseño cuantitativo examina el rendimiento predictivo y las métricas de interpretabilidad, mientras que el componente cualitativo analiza la percepción de transparencia por parte de analistas y responsables de marketing digital.

2. Población, muestra y fuentes de datos

La población está constituida por usuarios activos de plataformas de comercio electrónico y redes sociales. Se emplea una muestra no probabilística por conveniencia, basada en datasets anonimizados proporcionados por plataformas de analítica digital. Los datos incluyen variables como patrones de navegación, intensidad de interacción, historial de compras y respuestas a estímulos publicitarios. La curación y depuración de datos sigue lineamientos esenciales de calidad y gobernanza de datos (Sculley et al., 2015).

3. Técnicas de análisis y modelos predictivos

Se implementan modelos de Machine Learning supervisado, específicamente regresión logística, Random Forest y Gradient Boosting, seleccionados por su estabilidad y capacidad de capturar relaciones no lineales en el comportamiento de consumo (Friedman, 2001). Los modelos se entrena con un esquema de validación cruzada de k-folds y se comparan mediante métricas como AUC-ROC, MAE y precisión. Posteriormente, se aplican técnicas de Inteligencia Artificial explicable tales como SHAP y LIME, para evaluar la contribución marginal de cada variable y la coherencia de las explicaciones generadas, siguiendo las recomendaciones de Lundberg y Lee (2017).

4. Procedimientos de interpretación y validación de la transparencia algorítmica

La validación se estructura en dos fases:

- Validación técnica: análisis de estabilidad de las explicaciones, coherencia global y local, sensibilidad ante perturbaciones y robustez explicativa (Cai et al., 2019).
- Validación cognitiva: entrevistas semiestructuradas a expertos en analítica digital y responsables de marketing para evaluar la comprensibilidad y utilidad de los resultados. Este proceso se alinea con enfoques contemporáneos de interpretabilidad centrada en el usuario (Miller, 2019).

5. Consideraciones éticas y gestión responsable de datos

El estudio observa los principios de privacidad, minimización de datos y consentimiento informado, conforme a lineamientos de ética algorítmica actuales (Floridi & Cowls, 2019). Los datos se

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo
almacenar en infraestructura segura y los modelos se ejecutan sin comprometer la anonimidad de los usuarios.

Resultados


El modelo predictivo, analizado a través de técnicas de Inteligencia Artificial Explicable (XAI), revela que la probabilidad de compra está fuertemente impulsada por el comportamiento digital activo del usuario. Nuestros hallazgos confirman que existe una relación directa y ascendente entre el nivel de interacción digital y la propensión a la compra, legitimando las inversiones en estrategias de engagement y tráfico. En términos de importancia global, el Historial de Compras y las Interacciones Digitales son, por amplio margen, los factores más influyentes en la predicción, lo que sugiere que la clave del éxito reside en priorizar a los usuarios que demuestran actividad y compromiso recientes con la marca.

Un segundo hallazgo crucial se centra en la Sensibilidad al Precio, un factor que, aunque importante, actúa principalmente como un modulador y no como el impulsor dominante de la intención de compra. La distribución de usuarios muestra una concentración en una sensibilidad media o moderada, indicando que la mayoría de los clientes responden mejor a ofertas que añaden valor que a simples rebajas agresivas. Esto orienta estratégicamente a la compañía a evitar guerras de precios innecesarias, favoreciendo un enfoque de precios inteligentes y segmentados que maximicen el margen sin sacrificar la conversión.

Finalmente, la capacidad de explicación local que nos brinda el XAI permite una aplicación táctica altamente personalizada de estos conocimientos. Al entender el impacto individualizado de cada variable (ej. actividad alta versus sensibilidad al precio) en la decisión de un cliente específico, podemos generar acciones de marketing más precisas. Esta granularidad es esencial para tomar decisiones operativas, como ajustar las campañas de remarketing u ofrecer incentivos únicos a segmentos de alta propensión, asegurando que los recursos se dirijan a maximizar la conversión en el punto más eficiente del ciclo de vida del cliente.

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo


Gráfico N° 1. Relación entre interacciones Digitales y Probabilidad de Compra



Elaborado: Autora

Los puntos se concentran en una tendencia ascendente: a mayor interacción digital, mayor probabilidad predicha de compra. Este Gráfico N° 1 demuestra una relación directa entre el nivel de actividad digital del usuario y el incremento de la probabilidad de compra. El modelo de IA explicable (XAI) identifica esta variable como un motor clave de intención comercial. Para el área de marketing, estos resultados legitiman estrategias de inversión enfocadas en atraer tráfico y aumentar la frecuencia de interacciones.

Gráfico N° 2. Distribución de la Sensibilidad al Precio




Elaborado: Autora

Se observa una campana ligeramente sesgada hacia la derecha, indicando una mayor concentración de usuarios con sensibilidad de media a moderada (los valores más altos están a la derecha, pero la mayoría se agrupa en el centro). La distribución indica que la mayoría de clientes no son altamente sensibles al precio; responden mejor a incentivos de valor agregado que a rebajas agresivas; en

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

terminos predictivos, la IA reconoce esta variable como importante, pero no dominante, en la configuración de los patrones de consumo. Este hallazgo orienta a la empresa hacia estrategias de precios inteligentes y segmentadas.


Gráfico N° 3. Importancia Global de Variables (XAI)



Elaborado: Autora

El historial de compras y las interacciones digitales lideran el ranking de importancia, seguidos por sensibilidad al precio y factores contextuales. El modelo predice el consumo basándose en comportamiento pasado y reciente, lo cual es coherente con los principios de la economía del comportamiento. La importancia global obtenida mediante técnicas XAI (como Gini Importance o Permutation Importance) refuerza la transparencia del modelo, permitiendo priorizar acciones estratégicas en los segmentos con mayor propensión a compra.

Gráfico N° 4. Explicación Local para un Usuario (XAI tipo SHAP/LIME)



Elaborado: Autora

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

Las barras que indican impacto positivo (Interacciones Digitales e Historial de Compras) se extienden hacia la derecha, mientras que la barra de impacto negativo (Sensibilidad al Precio) se extiende hacia la izquierda, contrarrestando ligeramente el efecto. El impacto de Factores Contextuales es marginal. El modelo indica que este usuario tiene una alta probabilidad de compra gracias a su actividad digital y su historial de interacción previa. Sin embargo, su sensibilidad al precio modera el valor final. Este tipo de explicación local permite decisiones tácticas: ofertas personalizadas, recomendaciones individualizadas y ajustes en campañas de remarketing.

Discusión

La presente discusión se centra en la interpretación de los hallazgos derivados del modelo predictivo analizado con técnicas de eXplainable Artificial Intelligence (XAI), contrastándolos con el marco teórico y la literatura especializada en el comportamiento del consumidor y la modelización predictiva.

Coherencia con la Teoría del Comportamiento Digital

Nuestros resultados confirman la hipótesis central de que el comportamiento reciente y pasado es el predictor más robusto de la intención de compra. Específicamente, la alta jerarquía de la Importancia Global de las Interacciones Digitales y el Historial de Compras (Gráfico N° 3) es congruente con la Teoría de la Acción Razonada (TAR) y sus extensiones, donde la experiencia previa y la actividad repetida son proxies directos de la intención futura. El Gráfico N° 1, un diagrama de dispersión que muestra una relación directa y ascendente entre la interacción digital y la probabilidad de compra, proporciona una evidencia empírica de la fase de interés y consideración dentro del embudo de conversión digital. Este hallazgo valida la inversión en métricas de engagement y revalida la importancia de la frecuencia de exposición en entornos digitales.

El Rol Modulador, no Determinante, de la Sensibilidad al Precio

Contrario a la priorización tradicional de los modelos económicos puramente basados en la utilidad marginal, nuestro análisis indica que la Sensibilidad al Precio posee un rol modulador en la predicción, pero no es el factor dominante. La distribución de usuarios (Gráfico N° 2) evidencia un sesgo hacia la sensibilidad media-moderada, sugiriendo una propensión de la base de clientes a la preferencia por el valor agregado sobre la simple reducción de costos. La Explicación Local (Gráfico N° 4) ilustra este fenómeno claramente: el impacto negativo de la sensibilidad al precio en un usuario específico es contrarrestado por el fuerte impacto positivo de sus actividades comportamentales. Esta

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

dinámica es crucial, ya que sugiere que las estrategias de precios deben enfocarse en la segmentación inteligente y la personalización de la propuesta de valor, en lugar de la rebaja masiva, una conclusión alineada con la literatura reciente sobre la Economía del Comportamiento.

Fortalezas, Limitaciones y Direcciones Futuras

Fortalezas y Validez del Modelo

La principal fortaleza de este estudio reside en el empleo de técnicas XAI, proporcionando una transparencia interpretativa que supera las limitaciones de los modelos de caja negra. La explicación local (Gráfico N° 4) no solo valida la predicción, sino que también ofrece un soporte prescriptivo directo para la toma de decisiones tácticas a nivel de usuario individual. Esto incrementa la confianza en el modelo y facilita su adopción por parte de los stakeholders de negocio, al ofrecer una justificación clara de la jerarquía de variables (Gráfico N° 3).

Limitaciones y Proyecciones

Una limitación notable es la baja Importancia Global de los Factores Contextuales (Gráfico N° 3). Es posible que las variables contextuales incluidas en el modelo hayan sido insuficientes o que su influencia se haya diluido en el conjunto de datos. Futuras investigaciones deberían enfocarse en:

Enriquecimiento de Variables Contextuales: Incluir datos de eventos externos (ej. acciones de la competencia, tendencias sociopolíticas) y realizar análisis de feature engineering para capturar interacciones entre variables, lo que podría aumentar el poder explicativo de este factor.

Análisis Causal: Dado que el modelo establece una fuerte correlación predictiva, se requiere un diseño experimental (A/B testing) para establecer la causalidad directa entre el aumento inducido de las interacciones digitales y la probabilidad de compra, fortaleciendo la base teórica de la intervención.

Análisis de Robustez por Segmento: Investigar el modelo en subpoblaciones específicas (ej. clientes nuevos vs. recurrentes, alta vs. baja sensibilidad al precio) para determinar si la estructura de importancia de las variables se mantiene constante o si requiere la adaptación de modelos locales para cada segmento.

Conclusiones

- **Validación del Comportamiento como Principal Motor Predictivo:** El estudio confirma categóricamente la hipótesis de que el comportamiento digital activo y el historial de

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

compras son los factores más influyentes en la intención de compra. La alta jerarquía de las Interacciones Digitales e Historial de Compras como predictores primarios valida la estrategia de enfocar los recursos de marketing en el engagement y la fidelización, demostrando que la actividad digital es un indicador robusto de la proximidad a la conversión.

- El Precio como Factor Modulador, no Determinante: La Sensibilidad al Precio se establece como un factor modulador importante, pero no dominante, en la intención de compra. La evidencia de una concentración de usuarios con sensibilidad media a moderada implica que la base de clientes valora el producto por encima del coste, legitimando el desarrollo de estrategias de precios basadas en el valor agregado y la segmentación inteligente, en lugar de depender de rebajas masivas.
- Fortaleza en la Explicación Táctica mediante XAI: La aplicación de técnicas de XAI es una fortaleza central del modelo, proporcionando transparencia interpretativa que permite pasar de la predicción a la prescripción. La capacidad de generar explicaciones a nivel de usuario (Explicación Local) permite tomar decisiones tácticas hiper-personalizadas (ej. compensar la sensibilidad al precio con una oferta de alto valor) que optimizan la conversión de manera eficiente.
- Necesidad de Transición hacia el Análisis Causal: A pesar de la robustez predictiva, el modelo señala la necesidad de futuras investigaciones centradas en la causalidad. Para transformar la fuerte correlación observada entre Interacciones Digitales y probabilidad de compra en una ley de intervención de marketing, se requiere la realización de estudios experimentales (A/B testing) que validen si la manipulación estratégica de las interacciones efectivamente incrementa la intención de compra, además de enriquecer la modelización de los Factores Contextuales.

Referencias

1. Adebayo, J., Gilmer, J., Muelly, M., Goodfellow, I., Hardt, M., & Kim, B. (2018). Sanity checks for saliency maps. *Advances in Neural Information Processing Systems*, 31.
2. Akter, S. (2022). Algorithmic bias in machine learning-based marketing: sources and mitigation strategies. *Journal of Business Research* (article summary). <https://www.sciencedirect.com/science/article/pii/S0148296322000959>.

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

3. Alvarez-Melis, D., & Jaakkola, T. (2018). On the robustness of interpretability methods. arXiv:1806.08049.
4. Arrieta, A. B., et al. (2020). Explainable Artificial Intelligence (XAI): A survey. *Information Fusion*, 58, 82–115.
5. Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K., & Samek, W. (2015). On pixel-wise explanations by layer-wise relevance propagation. *PLOS ONE*, 10(7), e0130140.
6. Barocas, S., Hardt, M., & Narayanan, A. (2019). Fairness and machine learning.
7. Burrell, J. (2016). How the machine ‘thinks’: Understanding opacity in ML algorithms. *Big Data & Society*, 3(1).
8. Cai, C., Jonsson, L., & Tenenbaum, J. (2019). Interpretable machine learning: Moving from myth to practice. MIT Press.
9. Carvalho, D., Pereira, E., & Cardoso, J. (2019). Machine learning interpretability: A survey. *Journal of Information*, 11(2), 30–42.
10. Castelvecchi, D. (2016). Can we open the black box of AI? *Nature*, 538, 20–23.
11. Chen, J., et al. (2020). True to the model? SHAP explanations mismatch the model. arXiv:2006.16234.
12. Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv:1702.08608.
13. Floridi, L., & Cowls, J. (2019). A unified framework of five principles for AI in society. *Harvard Data Science Review*, 1(1).
14. Friedman, J. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232.
15. Guidotti, R., et al. (2019). A survey of methods for explaining black-box models. *ACM Computing Surveys*, 51(5).
16. Gunning, D., & Aha, D. (2019). DARPA’s Explainable AI program. *AI Magazine*, 40(2), 44–58.
17. Kumar, V., et al. (2021). Customer analytics and AI-driven personalization. *Journal of Retailing*.
18. Lepri, B., et al. (2018). Fair, transparent, and accountable algorithmic decision-making processes. DataPop Alliance / Research brief. <https://datapopalliance.org/wp-content/uploads/2018/09/DP-Research-Brief-Fair-Transparent-and-Accountable-Algorithmic-Decision-Making-Processes.pdf>

Inteligencia artificial explicable en la analítica digital: transparencia en los modelos predictivos de consumo

- content/uploads/2020/09/Fair-Transparent-and-Accountable-Algorithmic-Decision-making-Processes.pdf.
19. Lipton, Z. C. (2018). The mythos of model interpretability. *Communications of the ACM*, 61(10), 36–43.
 20. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.
 21. Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1–38.
 22. Molnar, C. (2022). *Interpretable Machine Learning* (2nd ed.).
 23. Morley, J., et al. (2020). Ethics of AI: A systematic review. MIT Press.
 24. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?” Explaining predictions of any classifier. *KDD*.
 25. Rudin, C. (2019). Stop explaining black box machine learning models. *Nature Machine Intelligence*, 1, 206–215.
 26. Samek, W., & Müller, K.-R. (2019). Towards explainable artificial intelligence. In *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning* (pp. 5–22). Springer.
 27. Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., ... & Dennison, D. (2015). Hidden technical debt in machine learning systems. *Advances in Neural Information Processing Systems*, 28.
 28. Selvaraju, R. R., et al. (2017). Grad-CAM: Visual explanations from deep networks. *ICCV*.
 29. Wachter, S., Mittelstadt, B., & Floridi, L. (2017). Why a right to explanation of automated decision-making does not exist in the GDPR. *International Data Privacy Law*, 7(2).
 30. Wang, D., et al. (2019). Designing theory-based XAI systems. *CHI*.
 31. Zhou, X., et al. (2021). Evaluating XAI: A multidimensional framework. *arXiv:2104.01490*.