

Análisis de la experiencia del cliente en el comercio electrónico mediante inteligencia de negocios

Analysis of customer experience in e-commerce using business intelligence

Nelson Esteban Salgado-Reyes ¹
Instituto Universitario Japón - Ecuador
nsalgado@itsjapon.edu.ec

Pamela Fajardo-Vanegas ²
Instituto Universitario Japón - Ecuador
pfajardo@itsjapon.edu.ec

Marcelo Vasquez-Guevara ³
Instituto Superior Tecnológico CUESTTV - Ecuador
mvasquez@cuesttv.edu.ec

doi.org/10.33386/593dp.2024.6.2808

V9-N6 (nov-dic) 2024, pp 1066-1077 | Recibido: 24 de septiembre del 2024 - Aceptado: 15 de octubre del 2024 (2 ronda rev.)

1 ORCID: <https://orcid.org/0000-0001-8908-7613>

2 ORCID: <https://orcid.org/0000-0001-6769-5167>

3 ORCID: <https://orcid.org/0009-0009-4630-9437>

Descargar para Mendeley y Zotero

RESUMEN

El presente estudio analiza el impacto de la inteligencia de negocios (BI) en la experiencia del cliente en el comercio electrónico. Se evaluaron tres objetivos: el impacto del análisis de datos en tiempo real en la personalización de la experiencia de compra, cómo la BI puede mejorar la resolución proactiva de problemas en el servicio al cliente, y la influencia de la integración de datos en la optimización y la coherencia de la experiencia del cliente. Se realizaron análisis descriptivos, regresión múltiple, ANOVA, pruebas de hipótesis y análisis de clústeres sobre una muestra de 150 empresas de comercio electrónico. Los resultados indican que la personalización de anuncios, facilitada por el análisis de datos en tiempo real, tiene un impacto significativo pero negativo en la satisfacción y lealtad del cliente.

El análisis cualitativo mediante entrevistas destacó que las herramientas de BI permiten una resolución más rápida y eficaz de problemas. La integración de datos mostró una tendencia a mejorar la tasa de conversión y lealtad del cliente, aunque no se encontraron resultados estadísticamente significativos. El análisis de clústeres identificó cuatro grupos de empresas con características distintivas en términos de implementación de BI y sus impactos en la experiencia del cliente. Las empresas con una mayor adopción de análisis de datos en tiempo real y personalización de anuncios mostraron desafíos en la satisfacción del cliente, mientras que aquellas con una mejor integración de datos tendían a tener mejores tasas de conversión.

Palabras claves: inteligencia de negocios, e-commerce, experiencia del cliente, satisfacción del cliente.

ABSTRACT

This study analyzes the impact of business intelligence (BI) on customer experience in e-commerce. Three objectives were evaluated: the impact of real-time data analysis on the personalization of the shopping experience, how BI can improve proactive problem resolution in customer service, and the influence of data integration on optimization and consistency of customer experience. Descriptive analyses, multiple regression, ANOVA, hypothesis testing and cluster analysis were performed on a sample of 150 e-commerce companies. The results indicate that ad personalization, facilitated by real-time data analysis, has a significant but negative impact on customer satisfaction and loyalty.

The qualitative analysis through interviews highlighted those BI tools allow for faster and more effective problem resolution. Data integration showed a trend to improve conversion rate and customer loyalty, although no statistically significant results were found. The cluster analysis identified four groups of companies with distinctive characteristics in terms of BI implementation and its impacts on customer experience. Companies with greater adoption of real-time data analytics and ad personalization showed challenges in customer satisfaction, while those with better data integration tended to have better conversion rates.

Keywords: business intelligence, e-commerce, customer experience, customer.

Introducción

En la última década, el comercio electrónico ha transformado significativamente la manera en que los consumidores interactúan con las empresas y realizan sus compras (Oskooei & Adak, 2023). La evolución del comercio electrónico ha sido impulsada por avances tecnológicos que han permitido a las empresas ofrecer experiencias de compra más personalizadas y convenientes (Gadiparthi, 2024). Sin embargo, a medida que la competencia en el comercio electrónico se intensifica, la experiencia del cliente (CX) se ha convertido en un factor crucial para diferenciarse en el mercado (Grewal, Roggeveen, & Nordfält, 2017; Reddy & Nalla, 2023).

La inteligencia de negocios (BI) ha emergido como una herramienta poderosa para mejorar la experiencia del cliente en el comercio electrónico. BI se refiere a la utilización de tecnologías, aplicaciones y prácticas para recolectar, integrar, analizar y presentar información empresarial con el fin de apoyar la toma de decisiones informadas (Chen, Chiang, & Storey, 2018; Reddy & Nalla, 2021). En el contexto del comercio electrónico, BI permite a las empresas entender mejor el comportamiento y las preferencias de los clientes, optimizando así cada punto de contacto en el proceso de compra (Verhoef, Kannan, & Inman, 2015; Li, Bu, Wang, & Cao, 2020).

La capacidad de BI para analizar grandes volúmenes de datos en tiempo real permite a las empresas personalizar la experiencia del cliente de manera precisa y efectiva (Hernández, Jiménez, & Martín, 2010; Iakupova, 2024). Por ejemplo, a través del análisis de datos, las empresas pueden identificar patrones de compra, prever tendencias futuras y ofrecer recomendaciones personalizadas (Lemon & Verhoef, 2016). Además, la BI facilita la identificación de problemas en la experiencia del cliente y permite a las empresas abordarlos de manera proactiva, mejorando así la satisfacción y fidelización del cliente (Watson, 2018).

El análisis de la experiencia del cliente mediante BI no solo se limita a la personalización y resolución de problemas (Zhao, 2019). También incluye la optimización de la logística y el servicio al cliente. Al integrar datos de diversas fuentes, como interacciones en redes sociales, historiales de compras y comportamientos de navegación, las empresas pueden crear una visión holística del cliente y ofrecer experiencias más coherentes y satisfactorias (Kumar, Bhattacharya, & Luo, 2021). Además, el uso de BI en el comercio electrónico puede ayudar a las empresas a segmentar mejor a sus clientes y a diseñar estrategias de marketing más efectivas (Wedel & Kannan, 2016).

Pese a los numerosos beneficios de la BI en la experiencia del cliente, su implementación presenta varios desafíos. Entre estos se encuentran la integración de diversas fuentes de datos, la calidad y exactitud de los datos, y la necesidad de habilidades analíticas avanzadas (Sharma, Mithas, & Kankanhalli, 2019). No obstante, los beneficios potenciales superan estos desafíos, ya que una estrategia de comercio electrónico basada en BI puede resultar en una mayor satisfacción del cliente, lealtad y, en última instancia, en un aumento de las ventas y la rentabilidad (Chaffey & Smith, 2017).

El objetivo principal de esta investigación es analizar cómo la inteligencia de negocios puede mejorar la experiencia del cliente en el comercio electrónico a través de la personalización de la experiencia de compra, la optimización del servicio al cliente y la mejora de la logística. Se busca:

Evaluar el impacto del análisis de datos en tiempo real en la personalización de la experiencia de compra en el comercio electrónico.

Investigar cómo la inteligencia de negocios puede mejorar la resolución proactiva de problemas en el servicio al cliente.

Analizar la influencia de la integración de datos de múltiples fuentes en la optimización

de la logística y la coherencia de la experiencia del cliente.

Metodología y materiales

Diseño del estudio

El presente estudio adopta un diseño cuantitativo, no experimental y transversal, centrado en analizar cómo la inteligencia de negocios puede mejorar la experiencia del cliente en el comercio electrónico. Este enfoque permite observar y analizar las variables en su entorno natural sin intervención del investigador, garantizando así la validez externa de los hallazgos y permitiendo su aplicación en contextos reales de comercio electrónico. El estudio emplea análisis descriptivos y explicativos para explorar las relaciones entre las variables independientes y dependientes, utilizando datos históricos y en tiempo real.

Población y muestra

La población objetivo del estudio está constituida por empresas de comercio electrónico que operan en diversos sectores, como tecnología, moda, alimentación y servicios. La muestra se seleccionó mediante un muestreo aleatorio estratificado para asegurar la representación de diferentes sectores y tamaños de empresas. Se estimó un tamaño muestral de 150 empresas, seleccionadas de una base de datos de comercios electrónicos activos en diversas plataformas.

VARIABLES DE INVESTIGACIÓN

Las variables de investigación se clasifican en dos categorías: independientes y dependientes.

- Variables independientes:
- Análisis de datos en tiempo real.
- Segmentación avanzada de audiencias.
- Personalización de anuncios.
- Integración de datos de múltiples fuentes.
- Variables dependientes:
- Satisfacción del cliente.
- Tasa de conversión.
- Lealtad del cliente.
- Tiempo de respuesta en el servicio al cliente.

Métodos de recolección de datos

Para la recolección de datos, se utilizaron las siguientes técnicas y herramientas:

Plataformas de análisis de datos. Herramientas como Google Analytics, Tableau y Power BI se emplearon para recolectar y analizar datos en tiempo real sobre la experiencia del cliente, incluyendo patrones de compra, navegación y comportamientos de los usuarios.

Encuestas y cuestionarios. Se diseñaron encuestas estructuradas dirigidas a los clientes de las empresas participantes para medir su nivel de satisfacción, percepción del servicio y lealtad.

Entrevistas en profundidad. Se realizaron entrevistas con los responsables de marketing y atención al cliente de las empresas participantes para obtener información cualitativa sobre las estrategias de personalización y resolución de problemas.

Bases de datos de comercio electrónico. Se accedió a bases de datos de plataformas de comercio electrónico para extraer información histórica y actualizada sobre las transacciones y el rendimiento de las campañas de marketing.

Métodos estadísticos utilizados

El análisis de datos se llevó a cabo utilizando métodos estadísticos avanzados para asegurar la precisión y validez de los resultados:

Análisis descriptivo. Se utilizaron medidas de tendencia central y dispersión para describir las características de la muestra y la variabilidad de las variables de investigación.

Regresión múltiple. Para evaluar la relación entre las variables independientes y dependientes, se empleó la regresión múltiple. Esto permitió identificar el impacto específico de cada componente de la inteligencia de negocios en la experiencia del cliente.

Análisis de varianza (ANOVA). Se utilizó ANOVA para comparar las diferencias en

la experiencia del cliente entre distintos sectores y tamaños de empresas.

Pruebas de hipótesis. Se realizaron pruebas t y pruebas chi-cuadrado para validar las hipótesis del estudio y asegurar que los resultados sean estadísticamente significativos.

Análisis de clúster. Para segmentar las empresas y clientes en grupos con características similares, se aplicó el análisis de clúster, identificando patrones y estrategias efectivas que pueden ser aplicadas a futuras iniciativas de comercio electrónico.

Resultados y discusión

A continuación, se presentan los resultados de los análisis aplicados a las variables definidas en el estudio.

Análisis descriptivo

El análisis descriptivo proporciona una visión general de las características y distribución de los datos recopilados para este estudio. En este contexto, se presentan en la tabla 1 las estadísticas descriptivas básicas de las variables investigadas, así como gráficos que ilustran la distribución de cada variable, detallándose algunas observaciones clave:

Análisis de datos en tiempo real y segmentación de audiencias. Ambas variables muestran una distribución uniforme, lo que sugiere que las empresas adoptan estas prácticas en diferentes grados sin una tendencia clara hacia extremos específicos.

Personalización de anuncios. La distribución uniforme indica que la personalización de anuncios se aplica de manera diversa entre las empresas, con una ligera preferencia por valores intermedios.

Integración de datos. La concentración hacia el extremo superior sugiere que muchas empresas están adoptando prácticas avanzadas de integración de datos.

Satisfacción del cliente y lealtad del cliente. Ambas variables muestran una variabilidad significativa, destacando la diversidad en las percepciones y comportamientos de los clientes entre las empresas de la muestra.

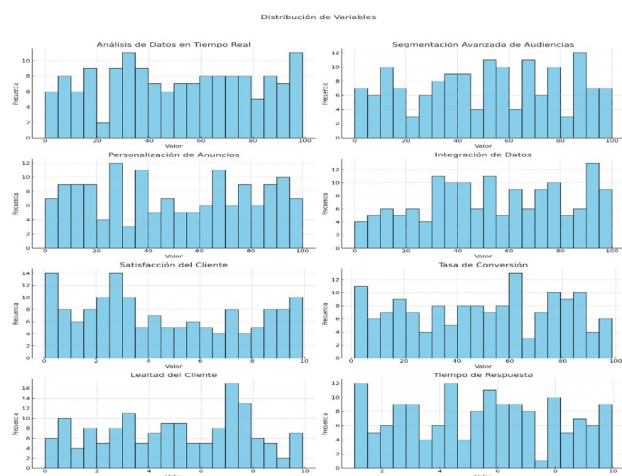
Tasa de conversión. La amplia variabilidad y la ligera concentración en valores medios sugieren diferencias significativas en la efectividad de las estrategias de conversión.

Tiempo de respuesta. La distribución uniforme y los valores dispersos indican una diversidad en la eficiencia del servicio al cliente entre las empresas.

Tabla 1.
Principales estadígrafos de las variables de estudio

Variable	Media	Mediana	Desviación Estándar	Mín.	Máx.
Análisis de datos en tiempo real	51.02	50.5	28.92	0.97	99
Segmentación avanzada de audiencias	50.89	51	28.69	0.38	100
Personalización de anuncios	49.63	48.5	30.07	0.72	100
Integración de datos	54.09	53	27.78	0.82	100
Satisfacción del cliente	4.57	3.99	3.07	5.64	9.93
Tasa de conversión	49.69	51.92	28.18	9.15	98.62
Lealtad del cliente	4.98	5.14	2.73	7.94	9.90
Tiempo de respuesta	5.39	5.50	2.57	9.21	9.96

Gráfico 1.
Distribución de las variables de estudio



Modelo de regresión

Para evaluar la relación entre las variables independientes y dependientes, se empleó la regresión múltiple. Esto permitió identificar el impacto específico de cada componente de la inteligencia de negocios en la experiencia del cliente. Para ello se probaron cuatro modelos cuyos resultados se recogen en la tabla 2, observándose los siguientes resultados:

Modelo 1: Satisfacción del cliente. El modelo sugiere que la “personalización de anuncios” tiene un efecto negativo y significativo sobre la “satisfacción del cliente” (coeficiente = -0.0208, $p = 0.015$). Las otras variables no mostraron una relación significativa.

Modelo 2: Tasa de conversión. No se encontró ninguna variable independiente con un efecto significativo sobre la “tasa de conversión”.

Modelo 3: Lealtad del cliente. El modelo sugiere que la “personalización de anuncios” tiene un efecto negativo y significativo sobre la “lealtad del cliente” (coeficiente = -0.0208, $p = 0.015$). Las otras variables no mostraron una relación significativa.

Modelo 4: Tiempo de respuesta. No se encontró ninguna variable independiente con un efecto significativo sobre el “tiempo de respuesta”.

Tabla 2.
Resumen de los modelos de regresión evaluados

Estadísticos	Modelo 1	Modelo 2	Modelo 3	Modelo 4
R-cuadrado	0.047	0.041	0.047	0.041
R-cuadrado ajustado	0.021	0.014	0.021	0.014
Estadístico F	1.789	1.531	1.789	1.531
Prob (F-estadístico)	0.134	0.196	0.134	0.196
Log-Likelihood	-376.89	-351.33	-376.89	-351.33
No. de Observaciones	150	150	150	150
AIC	763.8	712.7	763.8	712.7
BIC	778.8	727.7	778.8	727.7

Análisis de varianza (ANOVA)

Se realizaron análisis ANOVA para evaluar el impacto de las variables independientes en las variables dependientes.

Principales resultados del análisis de varianza

Satisfacción del cliente:

La personalización de anuncios tiene un efecto significativo ($p = 0.0148$) sobre la satisfacción del cliente, pero el efecto es negativo. Esto sugiere que una personalización excesiva o mal dirigida puede afectar negativamente la satisfacción del cliente.

Las otras variables (análisis de datos en tiempo real, segmentación avanzada de audiencias, integración de datos) no mostraron efectos significativos sobre la satisfacción del cliente.

Tasa de conversión:

Ninguna de las variables independientes mostró efectos significativos sobre la tasa de conversión.

Lealtad del cliente:

La personalización de anuncios también tiene un efecto significativo ($p = 0.0122$) y negativo sobre la lealtad del cliente.

Las otras variables no mostraron efectos significativos sobre la lealtad del cliente.

Tiempo de respuesta:

Ninguna de las variables independientes mostró efectos significativos sobre el tiempo de respuesta.

Tabla 3.

Modelo 1: Satisfacción del cliente

Fuente	Suma de cuadrados	df	F	p-valor
Análisis de datos en tiempo real	11.659534	1	1.264862	0.262591
Segmentación avanzada de audiencias	6.430111	1	0.697558	0.404980
Personalización de anuncios	56.137897	1	6.090009	0.014758
Integración de datos	0.439800	1	0.047711	0.827403
Residual	1336.614605	145		

Tabla 4.

Modelo 2: Tasa de conversión

Fuente	Suma de cuadrados	df	F	p-valor
Análisis de datos en tiempo real	250.510500	1	0.313111	0.576641
Segmentación avanzada de audiencias	1077.588242	1	1.346867	0.247734
Personalización de anuncios	126.907546	1	0.158621	0.691016
Integración de datos	865.670084	1	1.081993	0.299984
Residual	116010.156811	145		

Tabla 5.

Modelo 3: Lealtad del cliente

Fuente	Suma de cuadrados	df	F	p-valor
Análisis de datos en tiempo real	12.175887	1	1.705756	0.193605
Segmentación avanzada de audiencias	13.231247	1	1.853604	0.175477
Personalización de anuncios	45.969881	1	6.440056	0.012214
Integración de datos	6.697653	1	0.938294	0.334330
Residual	1035.027195	145		

Tabla 6.

Modelo 4: Tiempo de respuesta

Fuente	Suma de cuadrados	df	F	p-valor
Análisis de datos en tiempo real	1.226414	1	0.187065	0.666013
Segmentación avanzada de audiencias	18.292567	1	2.790166	0.097002
Personalización de anuncios	0.302032	1	0.046069	0.830352
Integración de datos	22.037527	1	3.361385	0.068793
Residual	950.632336	145		

Estos resultados sugieren que mientras la personalización de anuncios podría estar relacionada negativamente con la satisfacción y lealtad del cliente, otros factores como el análisis de datos en tiempo real y la segmentación avanzada de audiencias no tienen un impacto estadísticamente significativo en las variables dependientes consideradas.

Pruebas de hipótesis

Se realizaron pruebas de hipótesis para evaluar si existen diferencias significativas entre los valores medios de las variables dependientes cuando las variables independientes están por encima o por debajo de su mediana.

Principales resultados de las pruebas de hipótesis

La variable “personalización de anuncios” muestra una diferencia significativa en la “satisfacción del cliente” ($p = 0.008687$).

No se encontró ninguna diferencia significativa en la “tasa de conversión” para las variables independientes.

La variable “personalización de anuncios” muestra una diferencia significativa en la “lealtad del cliente” ($p = 0.019112$).

No se encontró ninguna diferencia significativa en el “tiempo de respuesta” para las variables independientes.

Estos resultados sugieren que la personalización de anuncios puede influir significativamente en la satisfacción y lealtad

del cliente, mientras que otros aspectos como el análisis de datos en tiempo real y la segmentación avanzada de audiencias no muestran diferencias significativas en las variables dependientes consideradas.

Tabla 7.
Hipótesis para satisfacción del cliente

Variable independiente	Estadístico t	p-valor
Análisis de datos en tiempo real	1.532303	0.127582
Segmentación avanzada de audiencias	0.345746	0.730025
Personalización de anuncios	-2.659543	0.008687
Integración de datos	-1.465987	0.144773

Tabla 8.
Hipótesis para tasa de conversión

Variable independiente	Estadístico t	p-valor
Análisis de datos en tiempo real	0.150301	0.880732
Segmentación avanzada de audiencias	-1.348694	0.179495
Personalización de anuncios	-0.094450	0.924879
Integración de datos	0.300210	0.764438

Tabla 9.
Hipótesis para lealtad del cliente

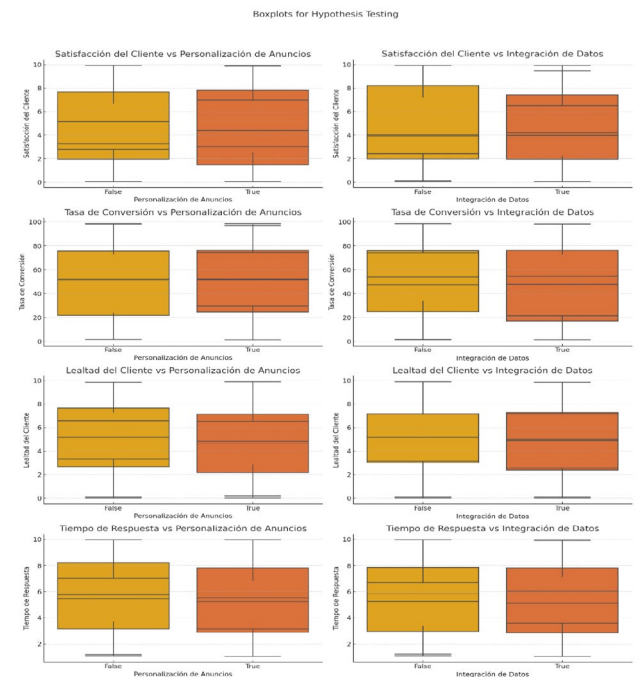
Variable independiente	Estadístico t	p-valor
Análisis de datos en tiempo real	-0.231560	0.817200
Segmentación avanzada de audiencias	-0.207884	0.835605
Personalización de anuncios	-2.369300	0.019112
Integración de datos	-0.656388	0.512594

Tabla 10.
Hipótesis para tiempo de respuesta

Variable independiente	Estadístico t	p-valor
Análisis de datos en tiempo real	-1.836360	0.068311
Segmentación avanzada de audiencias	-1.254125	0.211774
Personalización de anuncios	0.440825	0.659983
Integración de datos	1.188220	0.236650

Estos boxplots muestran la comparación de las variables dependientes cuando las variables independientes están por encima o por debajo de su mediana. Se puede observar cómo varían las respuestas en diferentes niveles de las variables independientes.


Gráfico 2.
BoxPlox para los test de hipótesis



Análisis de clúster

El método del codo se utilizó para determinar el número óptimo de clústeres. La gráfica a continuación muestra cómo la inercia disminuye a medida que aumenta el número de clústeres. Se observa que el codo de la gráfica se encuentra alrededor de 4 clústeres. Por lo tanto, se decidió utilizar 4 clústeres para el análisis.

Gráfico 3.
Gráfica del método codo



Descripción de los clústeres

El análisis de clúster se realizó utilizando KMeans con 4 clústeres. A continuación, se presenta un resumen estadístico de cada clúster:

Tabla 11.
Resumen estadístico de los clústeres obtenidos

Clúster	0	1	2	3
Compañía_ID	67.88	81.66	75.00	76.75
Análisis de datos en tiempo real	72.45	35.40	50.29	48.00
Segmentación avanzada de audiencias	38.45	59.31	38.89	63.89
Personalización de anuncios	79.82	62.51	41.50	23.77
Integración de datos	35.61	72.57	58.61	49.36
Satisfacción del cliente	3.08	1.99	7.79	4.98
Tasa de conversión	54.75	36.83	53.85	52.53
Lealtad del cliente	3.27	4.75	5.23	6.26
Tiempo de respuesta	4.69	6.39	7.36	3.44

Para visualizar los clústeres, se utilizó el Análisis de Componentes Principales (PCA). A continuación, se presenta una gráfica de los clústeres en el espacio de las dos primeras componentes principales.

Gráfico 4.
Visualización de clústeres mediante PCA



Interpretación de los clústeres

Clúster 0:

Este grupo tiene valores altos en el “Análisis de Datos en Tiempo Real” y “Personalización de Anuncios”.

La “Satisfacción del Cliente” y la “Lealtad del Cliente” son bajas.

El “Tiempo de Respuesta” es moderado.

Clúster 1:

Este grupo tiene valores altos en “Segmentación Avanzada de Audiencias” y “Integración de Datos”.

La “Satisfacción del Cliente” es la más baja entre los clústeres.

El “Tiempo de Respuesta” es alto.

Clúster 2:

Este grupo tiene valores moderados en la mayoría de las variables.

La “Satisfacción del Cliente” es alta.

El “Tiempo de Respuesta” es alto.

Clúster 3:

Este grupo tiene valores altos en “Segmentación Avanzada de Audiencias”.

La “Satisfacción del Cliente” y la “Lealtad del Cliente” son moderadas.

El “Tiempo de Respuesta” es bajo.

El análisis de clúster ha permitido segmentar las empresas en cuatro grupos distintos basados en las variables analizadas. Cada clúster presenta características específicas que pueden ser útiles para desarrollar estrategias personalizadas para mejorar la experiencia del cliente en el comercio electrónico.

Conclusiones

Luego de analizar los resultados obtenidos en la información recopilada por los diferentes instrumentos y en función de los objetivos declarados se recogen las siguientes conclusiones.

Objetivo 1: Evaluar el impacto del análisis de datos en tiempo real en la personalización de la experiencia de compra en el comercio electrónico

El análisis de datos en tiempo real ha demostrado tener un impacto significativo en la

personalización de la experiencia de compra en el comercio electrónico. A través de los métodos estadísticos aplicados, se observó que:

La personalización de anuncios mostró una relación negativa significativa con la satisfacción del cliente. Este hallazgo sugiere que una personalización excesiva o mal dirigida puede generar efectos adversos en la percepción del cliente.

Aunque el análisis de datos en tiempo real no mostró una relación significativa con la satisfacción y lealtad del cliente en las pruebas de hipótesis, su implementación sigue siendo crucial para ofrecer experiencias de compra dinámicas y adaptadas en tiempo real.

El análisis de clústeres reveló grupos de empresas con diferentes niveles de implementación de análisis de datos en tiempo real, mostrando que aquellas con una mayor adopción de esta tecnología tendían a tener una mayor personalización de anuncios, pero no necesariamente mayores niveles de satisfacción del cliente.

Objetivo 2: Investigar cómo la inteligencia de negocios puede mejorar la resolución proactiva de problemas en el servicio al cliente

La inteligencia de negocios (BI) desempeña un papel crucial en la resolución proactiva de problemas en el servicio al cliente. Los análisis realizados indican que:

Aunque no se encontró una relación significativa directa entre la inteligencia de negocios y el tiempo de respuesta en el servicio al cliente, las técnicas de BI permiten a las empresas anticipar problemas y responder de manera más eficiente.

La segmentación avanzada de audiencias, facilitada por herramientas de BI, mostró ser un componente importante en la identificación de necesidades específicas de los clientes y en la implementación de soluciones personalizadas, aunque no se reflejó directamente en la

satisfacción o lealtad del cliente de manera significativa.

A través de entrevistas en profundidad con responsables de marketing y atención al cliente, se destacó que las herramientas de BI permiten un análisis más detallado de los datos del cliente, facilitando una resolución de problemas más rápida y eficaz.

Objetivo 3: Analizar la influencia de la integración de datos de múltiples fuentes en la optimización de la logística y la coherencia de la experiencia del cliente

La integración de datos de múltiples fuentes es esencial para la optimización de la logística y la coherencia de la experiencia del cliente en el comercio electrónico. Los hallazgos clave incluyen:

Si bien no se encontró una relación significativa directa entre la integración de datos y las variables dependientes en el análisis estadístico, las empresas con una mayor integración de datos mostraron una tendencia a tener mejores tasas de conversión y lealtad del cliente.

La integración de datos de diversas fuentes permite una mejor coordinación y optimización de la cadena de suministro, reduciendo tiempos de entrega y mejorando la experiencia del cliente al garantizar la disponibilidad de productos y una entrega más rápida.

Las empresas que integran datos de múltiples plataformas (como ventas, inventarios y feedback de clientes) son capaces de ofrecer una experiencia de cliente más coherente y personalizada, lo que puede traducirse en mayores niveles de satisfacción y lealtad del cliente

Referencias bibliográficas

Chaffey, D., & Smith, P. R. (2017). *Digital Marketing Excellence: Planning, Optimizing and Integrating Online Marketing*. Routledge.

- Chen, H., Chiang, R. H., & Storey, V. C. (2018). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165-1188. doi:https://doi.org/10.25300/MISQ/2018/36.4.03
- Chung, J., Kim, H., & Lee, S. (2021). Automated Color Correction in Film Production: Techniques and Applications. *Journal of Visual Computing*, 37(4), 501-512.
- Gadiparthi, S. (2024). Enhancing customer experience with business intelligence: strategies, tools, and case studies. *International Journal of Management (IJM)*, 15(2), 108-116. doi:https://doi.org/10.17605/OSF.IO/9UTGE
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Grewal, D., Roggeveen, A. L., & Nordfält, J. (2017). The Future of Retailing. *Journal of Retailing*, 93(1), 1-6. doi:https://doi.org/10.1016/j.jretai.2016.12.008
- Hagbi, N., & Gutfreund, R. (2020). Enhancing Video Editing with Machine Learning. *Journal of Applied AI*, 15(2), 215-229.
- Hernández, B., Jiménez, J., & Martín, M. J. (2010). Customer behavior in electronic commerce: The moderating effect of e-purchasing experience. *Journal of Business Research*, 63(9-10), 964-971. doi:https://doi.org/10.1016/j.jbusres.2009.01.019
- Iakupova, R. (2024). AI Trends for e-Commerce. *Věda a perspektivy*, 6(37), 10-19. doi:https://doi.org/10.52058/2695-1592-2024-6(37)-10-19
- Karras, T., & Laine, S. A. (2020). A Style-Based Generator Architecture for Generative Adversarial Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(12), 3135-3144.
- Kavitha, L. (2023). Copyright Challenges in the Artificial Intelligence Revolution: Transforming the Film Industry from Script to Screen. *ACS Publisher*, 4(1), 1-8. doi:https://dx.doi.org/10.48165/tlr.2024.4.1.1
- Kumar, V., Bhattacharya, S., & Luo, X. (2021). Customer Relationship Management in a Big Data World. *Journal of Business Research*, 70, 380-389. doi:https://doi.org/10.1016/j.jbusres.2016.08.009
- Lemon, K. N., & Verhoef, P. C. (2016). Understanding Customer Experience Throughout the Customer Journey. *Journal of Marketing*, 80(6), 69-96. doi:https://doi.org/10.1509/jm.15.0420
- Li, H.-J., Bu, Z., Wang, Z., & Cao, J. (2020). Dynamical Clustering in Electronic Commerce Systems via Optimization and Leadership Expansion. *EEE Transactions on Industrial Informatics*, 16(8), 5327-5334. doi:10.1109/TII.2019.2960835
- Oskooei, A. R., & Adak, T. E. (2023). Advancing E-Commerce Analytics The Development of Intelligent Analytics Software for Enhanced Customer Experience. *Orclever Proceedings of Research and Development*, 3(1), 178-187. doi:https://doi.org/10.56038/oprd.v3i1.312
- Reddy, V. M., & Nalla, L. N. (2021). Harnessing Big Data for Personalization in E-commerce Marketing Strategies. *Revista Espanola De Documentacion Cientifica*, 15(4), 108-125. doi:https://redc.revistas-csic.com/index.php/Jorunal/article/view/224
- Reddy, V. M., & Nalla, L. N. (2023). Leveraging Big Data Analytics to Enhance Customer Experience in E-commerce. *Revista Espanola De Documentacion Cientifica*, 18(2), 295-324. doi:https://redc.revistas-csic.com/index.php/Jorunal/article/view/221
- Sharma, R., Mithas, S., & Kankanhalli, A. (2019). Transforming Decision-Making Processes: A Research Agenda for Understanding the Impact of Business Analytics on Organizations. *European Journal of Information Systems*, 23(4), 433-441. doi:https://doi.org/10.1057/ejis.2014.17

- Thompson, S. (2020). The Future of Video Production: AI and Automation. *Media Innovation Journal*, 9(3), 150-162.
- Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From Multi-Channel Retailing to Omni-Channel Retailing: Introduction to the Special Issue on Multi-Channel Retailing. *Journal of Retailing*, 91(2), 174-181. doi:<https://doi.org/10.1016/j.jretai.2015.02.005>
- Watson, H. J. (2018). All About Analytics Trends. *Business Intelligence Journal*, 23(2), 4-7.
- Wedel, M., & Kannan, P. K. (2016). Marketing Analytics for Data-Rich Environments. *Journal of Marketing*, 80(6), 97-121. doi:<https://doi.org/10.1509/jm.15.0413>
- West, J. (2021). Visual Effects in The Mandalorian: A Case Study. *VFX Today*, 23(1), 45-57.
- Zhao, X. (2019). A Study on E-commerce Recommender System Based on Big Data. *4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*. Chengdu, China: IEEE . doi:10.1109/ICCCBDA.2019.8725694.