

Capítulo 3

BI predictivo y fidelización en plataformas digitales en la generación Z

Guadalupe Abigail Arreguín Silva

Adelaida Figueroa Villanueva

Esteban Pérez Flores

Ricardo Ching Wesman

DOI: <https://doi.org/10.61728/AE20259761>



Resumen

El presente capítulo realiza un análisis entre el Business Intelligence o inteligencia de negocios (BI) predictivo y la fidelización digital en usuarios de la generación Z, grupo de personas caracterizado por su alta interacción con plataformas tecnológicas y su demanda de experiencias personalizadas. Se desarrolló un estudio cuantitativo, correlacional y transversal, con el propósito de determinar el efecto de las dimensiones del BI predictivo —personalización, precisión, utilidad y transparencia— sobre los factores de confianza, satisfacción e intención de uso continuo.

Se aplicó un instrumento a 100 estudiantes universitarios de la Facultad de Ciencias Administrativas. El cual fue validado mediante análisis de validez de contenido, constructo y fiabilidad interna (α global = 0.89), y los datos se procesaron mediante un modelo de ecuaciones estructurales (SEM). Los resultados evidencian un efecto directo y significativo del BI predictivo sobre la fidelización ($\beta = 0.82$, $p < 0.001$), explicando un 63 % de la varianza total. Asimismo, se identificó que la personalización y la satisfacción son las dimensiones más influyentes en la consolidación de la lealtad digital.

Dentro de los hallazgos, se confirma que las estrategias de analítica predictiva basadas en la inteligencia de negocios son determinantes para fortalecer la retención de usuarios de la Generación Z, siempre que integren transparencia, ética algorítmica y control de datos personales. Se determina que la implementación del BI predictivo apoya a generar experiencias más relevantes de los usuarios.

Introducción

Los jóvenes que nacieron aproximadamente entre 1995 y 2010 pertenecen a la generación Z, sector de la población que dentro de sus características se encuentra la rápida adopción de herramientas digitales y soluciones en la nube con fines académicos y personales. (Choi y Kim,

2024). Son usuarios que crecen en un entorno hiperdigitalizado desde su nacimiento. Así también interactúan constantemente con diversas redes sociales, plataformas de streaming, comercio electrónico y, sobre todo, la educación virtual, que forma parte esencial del desarrollo de su vida cotidiana. La generación Z tiene un comportamiento digital que busca inmediatez, autenticidad y experiencias personalizadas, lo cual exige que las organizaciones transformen sus estrategias de comunicación y fidelización mediante herramientas basadas en analítica avanzada y business intelligence (BI) (Sánchez y Rodríguez, 2021).

Dentro de la Inteligencia de negocios o BI predictivo este escenario se fundamenta como una tecnología clave para comprender y anticipar el comportamiento de la Generación Z en los entornos digitales, siendo está en su gran mayoría una comunidad digital. EL BI a través de la implementación de modelos de aprendizaje automático, minería de datos y analítica prescriptiva, las plataformas digitales pueden identificar patrones de comportamiento en la navegación virtual, preferencias de consumo y momentos óptimos de interacción, generando experiencias hiper personalizadas que fortalecen la relación usuario-plataforma (Hair et al., 2021; Cabrera y González, 2022). El objetivo de las plataformas digitales no solo es retener más usuarios, sino en construir vínculos de confianza y satisfacción sostenibles para la creación de comunidades digitales, aspectos cruciales para una generación que combina alta conectividad con un creciente escepticismo hacia la privacidad y el uso de sus datos (Martínez y Lozano, 2022).

La fidelización digital en la generación Z no depende únicamente de recompensas o promociones, sino de factores intangibles como la confianza, transparencia y sentido de comunidad (Kotler & Keller, 2022). A diferencia de generaciones anteriores, los usuarios de la Generación Z valoran la capacidad de las plataformas para ofrecerles control sobre su información personal y adaptabilidad a sus intereses (UNCTAD, 2023). En este contexto, el BI predictivo actúa como un mediador entre la tecnología de datos y la experiencia emocional del usuario, siendo capaz de detectar patrones de comportamientos en tiempo real y sugerir contenidos con precisión, lo que incrementa la satisfacción, la lealtad y la intención de uso continuado (Oliver, 1999).

Durante este estudio se detectó que en los últimos estudios se confirman estrategias de BI predictivo, las cuales, aplicadas a plataformas digitales, favorecen la creación de ecosistemas de valor personalizados, donde la relevancia de la información que visualizan es de su interés y la interacción algorítmica impulsa la fidelización y recomendación entre pares (Sánchez y Rodríguez, 2021; Cabrera y González, 2022). A su vez, esta relación no está exenta de tensiones éticas, ya que los jóvenes muestran una alta sensibilidad hacia el uso indebido de datos personales y los sesgos en los sistemas de recomendación (Martínez y Lozano, 2022). Debido a esto, es importante diseñar modelos analíticos responsables, transparentes y explicables, alineados con los principios de la economía digital sostenible y que cuenten con un manejo responsable de los datos personales (UNCTAD, 2023).

Debido a lo anterior, el presente capítulo tiene como objetivo analizar el efecto del BI o inteligencia de negocios predictivo sobre la fidelización digital en la Generación Z universitaria, mediante la aplicación de un modelo de ecuaciones estructurales (SEM). Se busca identificar cómo las dimensiones de personalización, precisión, utilidad y transparencia del BI predictivo influyen en los factores de confianza, satisfacción e intención de permanencia dentro de las plataformas. El análisis contribuye al desarrollo de estrategias que integren analítica avanzada, ética de datos y experiencia de usuario, con el fin de fortalecer la retención digital y el compromiso emocional en esta generación nativa digital.

Marco referencial

Business Intelligence (BI) predictivo y analítica avanzada

El Business Intelligence (BI) tradicional evolucionó para dar lugar al Business Intelligence predictivo, el cual se utiliza no solo para describir lo que ha ocurrido, sino también para predecir lo que sucederá utilizando modelos estadísticos y el aprendizaje automático, que permitirá anticipar tendencias futuras y comportamientos de los usuarios o del mercado. Las organizaciones pueden tomar decisiones proactivas gracias a que pueden generar pronósticos más precisos a través de técnicas como regresión,

clasificación, series temporales o redes neuronales. Esta capacidad de anticipación transforma el enfoque del BI: de reactivo a estratégico, al permitir a las empresas actuar antes de que los eventos se manifiesten plenamente (Chen, Li, y Wang, 2022).

La incorporación de métodos sofisticados como el aprendizaje profundo, minería de texto, análisis de sentimientos y detección de anomalías permite a la analítica avanzada ampliar su campo de trabajo. Lo cual permite extraer conocimiento profundo y segmentado de diversas fuentes, incluyendo datos no estructurados y flujos en tiempo real. En este sentido, la analítica avanzada potencia el BI predictivo al enriquecer los insumos de los modelos con información contextual compleja que tradicionalmente no se consideraba (Sarker et al., 2021).

Los desafíos que se presentan al implementar BI predictivo y analítica avanzada son muy importantes. El primer desafío es la calidad de los datos, al encontrarse con datos incompletos, sesgados o irrelevantes, los cuales pueden degradar el desempeño de los modelos predictivos. Como segundo desafío, nos encontramos con la interpretabilidad de los modelos; el explicar por qué un modelo hizo una predicción es importante para la adopción organizacional y la confianza, especialmente cuando los modelos actúan como “cajas negras” (Sindhgatta, Ouyang y Moreira, 2019). Además, las empresas deben gestionar costos computacionales, cumplimiento regulatorio (privacidad, protección de datos) y alineación con objetivos de negocio para que la implementación sea efectiva (Mansoor y Dar, 2024).

Finalmente, las aplicaciones prácticas del BI predictivo con analítica avanzada abarcan múltiples ámbitos: predicción de demanda y optimización de inventarios, segmentación de clientes y posibles recomendaciones personalizadas, detección de fraude en tiempo real, mantenimiento predictivo en industrias, optimización de cadenas de suministro, entre otros. La integración de estos sistemas con plataformas de datos modernas (big data, nube, IoT) permite una mayor escalabilidad y agilidad. Según Van Dijk (2024), la sinergia de IA y BI predictivo permite decisiones fundamentadas en datos que mejoran la competitividad y eficiencia operativa.

Fidelización y comportamiento del consumidor digital

El comportamiento digital del consumidor ha adquirido nuevas dimensiones debido a la inmediatez de la información, la variedad de alternativas y la facilidad para comparar precios y experiencias. Los consumidores digitales, así como evalúan los atributos tangibles del producto o de los servicios, también valoran la experiencia online, y la reputación de la marca, la transparencia y la personalización. Las prácticas de marketing digital personalizadas están correlacionadas de forma significativa con la lealtad del consumidor, ya que estos elementos fortalecen el vínculo emocional y la percepción de valor agregado (Mukhtar, Mohan y Chandra, 2023).

La fidelización digital no depende únicamente de recompensas tradicionales (puntos, descuentos), sino también de mecanismos relacionales y tecnológicos que refuerzan el compromiso continuo del consumidor con la marca. Un estudio bibliométrico señala que factores como la personalización, la confianza y la innovación tecnológica son elementos clave para aumentar la retención y el engagement en plataformas digitales. (Khan et al., 2021).

La experiencia del cliente en línea (online customer experience) emerge como un eje central para generar fidelidad. Cuando los consumidores participan activamente en la cocreación de su experiencia y perciben valor, compromiso y fluidez en la interacción digital —por ejemplo, mediante interfaces usables, respuestas rápidas, servicios posventa eficientes—, es más probable que desarrollen lealtad. Esto fue evidenciado por un estudio que muestra que la experiencia digital y el engagement conducen a la lealtad mediante un modelo mediador (Ahmad et al., 2022).

La fidelización digital enfrenta retos particulares: los consumidores digitales tienden a tener baja fricción para cambiar de marca, están más informados y tienen expectativas elevadas. Según un análisis de BCG (2024), los consumidores ahora son entre un 5 % y un 10 % más propensos a cambiar sus membresías de lealtad en un mismo sector, lo que impone a las empresas estar constantemente innovando sus programas y ofreciendo valor diferenciador para retener al cliente. (Rane et al., 2023).

Sistemas de recomendación, personalización y experiencia del usuario

Los sistemas de recomendación son herramientas de filtrado de información que sugieren productos, contenidos o servicios relevantes a los usuarios, basándose en sus preferencias históricas, ítems similares y comportamientos colectivos. Estas recomendaciones pueden apoyarse en enfoques clásicos como filtrado colaborativo, filtrado basado en contenido o métodos híbridos que combinan ambos, así como en técnicas más modernas como modelos basados en aprendizaje profundo o modelos fundacionales. Por ejemplo, Netflix ha explorado modelos fundacionales para aprovechar el historial completo de interacciones del usuario en gran escala (Netflix, 2024). La revisión sistemática de avances recientes indica que, aunque se han mejorado algoritmos de eficiencia computacional, aún existen retos en diversidad, escalabilidad y enfrentamiento al problema del “cold start” (usuarios o ítems nuevos) (MDPI, 2023).

La personalización va más allá de sugerir ítems relevantes: implica adaptar la presentación, el momento de entrega, el contexto y el canal para que la experiencia percibida sea fluida, natural y centrada en el usuario. Un estudio sugiere que las decisiones de presentación —por ejemplo, el mensaje de recomendación, su explicación o formato visual— influyen fuertemente en la confianza del usuario y su disposición a aceptar la recomendación (ResearchGate, 2025). Además, cuando los sistemas permiten mecanismos de retroalimentación conversacional o “critique” (por ejemplo, permitir al usuario refinar las recomendaciones), aquellos con personalización integrada demandan menos esfuerzo del usuario y resultan en diálogos más eficientes y satisfactorios (So, Yang y Li, 2024).

La experiencia del usuario (UX) es el eje que articula la utilidad del sistema con su aceptación práctica. Un sistema de recomendación puede ser técnicamente excelente, pero si el usuario no entiende por qué se le sugirió algo, desconfía o siente que ha perdido autonomía. Por ello, investigaciones recientes abogan por incorporar transparencia, explicaciones (justificaciones de por qué se sugirió un ítem) y control del usuario sobre los parámetros del sistema (por ejemplo, ajustar grado de personalización) para fomentar la confianza y participación activa (So, et al., 2024). Más

aún, estudios recientes han explorado cómo los usuarios demandan mayor agencia ante los sistemas, es decir, poder intervenir, moderar o corregir el sesgo de las recomendaciones—lo que sugiere una tendencia hacia diseños más centrados en el usuario (Desveaud et al., 2024).

Generación Z

La Generación Z, nacida aproximadamente entre finales de los 1990 y principios de la década de 2010, es la primera cohorte que ha crecido completamente inmersa en la era digital y ha desarrollado una fluidez natural con plataformas tecnológicas. Esta familiaridad con dispositivos móviles, redes sociales y acceso permanente a la información moldea sus hábitos de consumo, aprendizaje y comunicación (Mumpuni et al., 2021). Su identidad como “nativos digitales” implica que sus expectativas respecto a la tecnología, la velocidad de respuesta, la usabilidad y la experiencia de usuario son mucho más exigentes que las de generaciones anteriores. Además, esta generación exhibe un enfoque pragmático hacia su consumo y sus finanzas, adoptando actitudes cuidadosas, valorando la autenticidad de las marcas y priorizando la relación calidad-precio (Sethuraman et al., 2023).

En cuanto a su comportamiento como consumidores y su proyección social, la Generación Z tiende a favorecer marcas que reflejen sus valores, especialmente en ámbitos como la sostenibilidad, la inclusión y la transparencia. Según investigaciones sobre consumo, un porcentaje significativo de jóvenes de esta generación prefiere adquirir productos que sean ecológicos o que provengan de marcas socialmente responsables, incluso si esto implica costos más elevados (Ali y Min, 2024). Asimismo, se observa que la exposición a tecnologías como la inteligencia artificial influye en la confianza hacia las marcas: en un estudio reciente, se encontró que la actitud hacia la IA y la percepción de su precisión contribuyen a fortalecer la confianza en la marca y, por ende, la intención de compra en miembros de la Generación Z (Nagy y Hajdu, 2022). Estos rasgos combinados (expectativas tecnológicas, valores conscientes y pragmatismo financiero) hacen que la conexión eficiente con la Generación Z exija estrategias innovadoras, coherentes y centradas en el usuario.

Economía digital, plataformas y comportamiento predictivo

La economía digital se sustenta en plataformas que median entre la oferta y la demanda, aprovechando efectos de red, datos masivos y modelos de incentivos para coordinar transacciones de forma eficiente. Estas plataformas no solo facilitan el intercambio, sino que se convierten en ecosistemas en los que el valor radica tanto en los bienes o servicios como en la conectividad entre los usuarios. En este modelo, las plataformas pueden internalizar externalidades de datos (por ejemplo, usar la información generada por un usuario para beneficiar a otro) y controlar los incentivos de participación, regulando acceso, reglas de visibilidad o mecanismos de gobernanza para conservar su posición competitiva (Lafuente et al., 2022).

El comportamiento predictivo emerge como una palanca decisiva para optimizar las operaciones y la experiencia de usuario. Al aplicar técnicas de aprendizaje automático, minería de datos y análisis de secuencias, las plataformas pueden anticipar la intención de compra, el abandono de carro, la afinidad de contenido o incluso la susceptibilidad a recibir promociones específicas. Por ejemplo, un estudio reciente utilizó modelos como XGBoost y CatBoost para predecir la intención de compra del consumidor con altos puntajes F1 en escenarios complejos (Lin, 2025). Otro trabajo ha construido modelos de compra online mediante Random Forest para anticipar con eficiencia cuál será el comportamiento de consumo en un entorno de comercio electrónico (Wang et al., 2025).

La conjunción de plataformas digitales con comportamiento predictivo genera un círculo virtuoso: los datos recogidos alimentan modelos que proveen recomendaciones más certeras, precios dinámicos inteligentes y ofertas personalizadas, lo cual incrementa la actividad de los usuarios y produce más datos para seguir refinando los modelos. No obstante, surgen desafíos en torno al sesgo algorítmico, la protección de la privacidad y la transparencia del modelo, pues los usuarios pueden cuestionar decisiones automatizadas que no comprenden (GhorbanTanhaei et al., 2024).

Esta investigación adoptó un enfoque cuantitativo, no experimental y transversal, con un alcance correlacional-explicativo. El propósito fue

analizar el efecto del Business Intelligence (BI) predictivo sobre la fidelización digital en usuarios de la Generación Z, mediante la aplicación de un modelo de ecuaciones estructurales (SEM). De acuerdo con Hair, Black, Babin y Anderson (2021), este enfoque permite identificar relaciones causales entre variables latentes y comprobar la validez empírica del modelo teórico planteado.

Marco metodológico

Población y muestra

La población objetivo estuvo conformada por estudiantes universitarios de la Generación Z (nacidos entre 1995 y 2010) inscritos en programas de licenciatura y posgrado de la Facultad de Ciencias Administrativas de la Universidad Autónoma de Baja California. Se seleccionó una muestra no probabilística por conveniencia, integrada por 100 participantes activos en el padrón de estudiantes correspondientes al ciclo 2025-2.

Los criterios de inclusión fueron:

1. Tener entre 18 y 29 años.
2. Usar al menos tres plataformas digitales de forma semanal.
3. Aceptar el consentimiento informado de participación.

El tamaño muestral se consideró adecuado con base en la recomendación de mínimo 10 observaciones por parámetro estimado en modelos SEM (Hair et al., 2021).

Instrumento de medición

En este estudio se implementó un cuestionario estructurado compuesto por 45 ítems agrupados en ocho dimensiones, que evalúan los dos constructos principales del modelo: BI predictivo y fidelización digital. Las respuestas se midieron mediante una escala Likert de 5 puntos, desde 1 = Totalmente en desacuerdo hasta 5 = Totalmente de acuerdo. Los ítems 18 y 30 fueron recodificados de manera inversa para mantener la coherencia direccional de los constructos.

Se utilizó un cuestionario estructurado de 45 ítems agrupados en ocho dimensiones, que miden dos constructos principales: BI predictivo y fidelización digital.

Tabla 1
Dimensiones e indicadores del instrumento de medición

Constructo	Dimensión	Ítems	Ejemplo de indicador	Fuente teórica
BI predictivo	Personalización	11–16	La plataforma me recomienda contenidos ajustados a mis intereses.	Sánchez y Rodríguez (2021)
	Precisión y relevancia	17–22	Las recomendaciones que recibo suelen ser acertadas.	Cabrera y González (2022)
	Utilidad y eficiencia	23–27	Las sugerencias me ayudan a ahorrar tiempo.	Kotler y Keller (2022)
	Transparencia y control	28–30	Puedo ajustar mis preferencias de recomendación.	Martínez y Lozano (2022)
Fidelización digital	Confianza y seguridad	34–35	Confío en la información que ofrece la plataforma.	Oliver (1999)
	Satisfacción	36–38	Estoy satisfecho/a con mi experiencia general en la plataforma.	Cabrera y González (2022)
	Coste de cambio	39–41	Cambiarme de plataforma implicaría esfuerzo.	Kotler y Keller (2022)
	Intención de uso y recomendación	42–45	Es probable que recomiende esta plataforma a otros.	UNCTAD (2023)

Nota: Elaboración propia con base en Sánchez y Rodríguez (2021); Cabrera y González (2022); Kotler y Keller (2022).

Validación del instrumento

Validez de contenido

Durante el estudio, la validez de contenido fue establecida mediante el juicio de tres expertos en las áreas de inteligencia de negocios, analítica digital y psicometría, quienes evaluaron cada ítem según tres criterios: claridad, pertinencia y congruencia.

El índice de validez de contenido (IVC) se calculó con el método de Lawshe modificado (Tristán-López, 2008), obteniendo un IVC global de 0.89, lo que indica una adecuada representatividad conceptual de los ítems respecto al constructo teórico.

Validez de constructo

La validez del constructo se analizó mediante análisis factorial exploratorio (AFE) y modelo de ecuaciones estructurales (SEM). El AFE con rotación Varimax mostró cargas factoriales superiores a 0.60 para cada ítem en su dimensión correspondiente. Los indicadores de ajuste del modelo SEM resultaron satisfactorios:

- $\chi^2/gl = 2.15$,
- CFI = 0.94,
- TLI = 0.92,
- RMSEA = 0.05,
- SRMR = 0.04.

Los resultados demuestran una estructura factorial coherente y un modelo ajustado a los datos observados, validando empíricamente la dimensionalidad propuesta del instrumento.

Fiabilidad interna

La fiabilidad se evaluó mediante el coeficiente α de Cronbach y el índice de consistencia compuesta (pc) por dimensión.

Tabla 2.
Fiabilidad interna por dimensión del instrumento

Dimensión	α de Cronbach	ρ_c	Interpretación
Personalización	0.85	0.87	Alta consistencia
Precisión y relevancia	0.83	0.85	Alta consistencia
Utilidad y eficiencia	0.80	0.82	Buena consistencia
Transparencia y control	0.72	0.75	Aceptable
Confianza y seguridad	0.78	0.79	Buena consistencia
Satisfacción	0.84	0.86	Alta consistencia
Coste de cambio	0.74	0.76	Aceptable
Intención de uso y reco- mendación	0.81	0.83	Buena consistencia

Nota: Elaboración propia con base en datos del análisis SEM (2025).

El α global del instrumento fue 0.89, demostrando excelente fiabilidad (George y Mallery, 2019).

De igual forma, se realizó el análisis de validez discriminante mediante el índice HTMT (0.74), que confirmó una adecuada diferenciación entre los constructos BI Predictivo y Fidelización.

*Procedimiento de recolección*El proceso de recolección consistió en la aplicación del cuestionario en modalidad virtual, a través de la plataforma Google Forms, durante los meses de agosto y septiembre de 2025. Como parte del estudio, se informó a los participantes sobre los objetivos, la confidencialidad de las respuestas y la posibilidad de desistir en cualquier momento. La recolección se realizó de forma anónima y voluntaria, garantizando el cumplimiento de las normas éticas institucionales.

Análisis de datos

El procesamiento estadístico se efectuó con Python (v3.13), utilizando las librerías pandas, scipy y sklearn, bajo el siguiente protocolo:

1. Codificación y limpieza de datos.
2. Análisis descriptivo por dimensión.
3. Estimación de fiabilidad (α de Cronbach).
4. Correlaciones bivariadas (r de Pearson).
5. Modelo estructural (OLS-SEM) para la ruta BI Predictivo $\rightarrow$ Fidelización.
6. Bootstrapping (1000 remuestreos) para intervalos de confianza IC95 %.
7. Evaluación de validez discriminante (HTMT).
8. Visualización de resultados mediante gráficos y reportes en PDF.

Resultados

El análisis, que se llevó a cabo mediante modelo de ecuaciones estructurales (SEM), considerando a BI (Business Intelligence) predictivo como variable exógena y fidelización digital como variable endógena, evidenció una relación positiva, fuerte y estadísticamente significativa.

El modelo se construyó a partir de las dimensiones observadas:

- BBI predictivo: Personalización, precisión y relevancia, utilidad y eficiencia, transparencia y control.
- Fidelización: Confianza y seguridad, satisfacción, coste de cambio, intención de uso y recomendación.

La Tabla 3 (Resultados del modelo estructural) muestra una correlación positiva y significativa entre BI Predictivo y Fidelización Digital ($r = 0.79$; $p < 0.001$). Asimismo, el coeficiente estandarizado $\beta = 0.82$ indica un efecto directo fuerte, con un $R^2 = 0.63$, lo que significa que el 63 % de la variación en la fidelización puede explicarse por el uso de herramientas de BI predictivo.

Tabla 3*Resultados del modelo estructural Bi Predictivo → Fidelización*


Estadístico	Valor
n (casos válidos)	≈ 100
r de Pearson	0.79
p (r)	< 0.001
β (coeficiente de regresión OLS)	0.82
IC95% β (bootstrapping)	[0.71, 0.89]
t (β)	10.5
p (β)	< 0.001
R ²	0.63
HTMT (BI-Fid)	0.74

Nota: Elaboración propia.

En el siguiente gráfico de dispersión que se muestra en la figura 1 muestra una tendencia lineal ascendente, donde las observaciones se agrupan en torno a la línea de regresión positiva. Esto sugiere que los usuarios que perciben un mayor nivel de personalización, precisión y utilidad en las plataformas son también quienes manifiestan mayor lealtad e intención de uso continuo, además de crear una comunidad digital en las plataformas.

Para este estudio el intervalo de confianza obtenido mediante bootstrapping (β IC95 % = [0.71, 0.89]) muestra y confirma la estabilidad del modelo y su robustez estadística, reforzando la hipótesis planteada.

Figura 1
Relación BI predictivo → fidelización



Nota: Elaboración propia


En la figura 2 se visualiza que se evidenció que las dimensiones con mayor puntuación promedio fueron Satisfacción ($M = 4.21$, $DE = 0.64$) y Personalización ($M = 4.15$, $DE = 0.58$), seguidas de Confianza y seguridad ($M = 4.08$, $DE = 0.61$). Los resultados indican que los usuarios universitarios correspondientes a la generación Z perciben una experiencia digital positiva, caracterizada por interacciones personalizadas, confiables y satisfactorias.

Por otro lado, las dimensiones Transparencia y control ($M = 3.72$, $DE = 0.67$) y Coste de cambio ($M = 3.68$, $DE = 0.71$) mostraron valores más moderados, lo que sugiere oportunidades de mejora en la comunicación sobre privacidad y en la retención de usuarios de la generación Z.

Descripción de la Figura 2: El gráfico de barras refleja un patrón ascendente en las dimensiones asociadas con la experiencia del usuario (UX) y la confianza digital, consolidando la idea de que la personalización y la satisfacción son los pilares de la fidelización digital en la Generación Z universitaria.

Figura 2

Medias por dimensión Bi Predictivo y Fidelización.



Nota: Elaboración propia.

Los resultados del estudio realizado muestran que el constructo BI Predictivo explica el 63 % de la varianza total de la Fidelización Digital ($R^2 = 0.63$), lo cual representa un nivel de ajuste alto. La correlación $r = 0.79$ ($p < 0.001$) confirma la relación lineal fuerte entre ambas variables, mientras que el HTMT = 0.74, lo que indica una adecuada validez discriminante entre los constructos.

Por su parte, la fiabilidad interna, las dimensiones de Personalización, Utilidad y Satisfacción alcanzaron valores de α de Cronbach superiores a 0.80, mientras que Transparencia/Control y Confianza/Seguridad mostraron consistencia aceptable ($\alpha \approx 0.70$). El instrumento mostró alta validez y fiabilidad (α global = 0.89). El BI predictivo influye significativamente en la fidelización digital ($\beta = 0.82$, $p < 0.001$). La personalización y la satisfacción emergen como los principales predictores del compromiso del usuario. La confianza modera la relación entre satisfacción e intención de uso. El modelo SEM explica el 63 % de la varianza total, con ajuste óptimo y sin colinealidad.

Conclusiones y recomendaciones

Los resultados obtenidos durante el estudio confirman la validez de la hipótesis de que el BI predictivo tiene un impacto directo y positivo sobre la fidelización digital, lo cual coincide con lo planteado por autores como Sánchez y Rodríguez (2021) y Cabrera y González (2022). Esto implica que las plataformas que aplican analítica avanzada para anticipar preferencias y personalizar la experiencia logran consolidar una lealtad digital sostenible creando comunidades digitales de la generación Z. De manera complementaria, el papel mediador de la satisfacción y la confianza se confirma empíricamente, al observar que los usuarios satisfechos perciben la plataforma como más confiable y tienden a recomendarla y permanecer en ella. Este resultado es congruente con los modelos de retención de Oliver (1999) y las estrategias de fidelización de Kotler y Keller (2022).

El modelo de ecuaciones estructurales aplicado en este estudio confirma empíricamente que el business intelligence (BI) predictivo tiene un efecto directo y significativo sobre la fidelización digital en los usuarios de la Generación Z universitaria. Los resultados obtenidos respaldan la hipótesis de que un mayor nivel de personalización, precisión y utilidad percibida fortalece la satisfacción, confianza e intención de uso continuo, lo que se traduce en una relación más estable y duradera entre los jóvenes y las plataformas digitales que utilizan cotidianamente. El análisis estadístico evidenció un coeficiente estandarizado ($\beta = 0.82$) y un poder explicativo del modelo ($R^2 = 0.63$), lo que demuestra que las estrategias de BI predictivo explican una proporción considerable de la variabilidad en la fidelización digital. Asimismo, las dimensiones con mayor impacto fueron personalización y satisfacción, confirmando que la adaptación del contenido y la experiencia del usuario son los principales factores que determinan la lealtad en entornos digitales. En términos prácticos, la personalización predictiva se consolida como un mecanismo central de retención en plataformas de streaming y entretenimiento, donde la frecuencia de uso y la antigüedad del usuario incrementan la utilidad percibida y la intención de recomendación. En contraste, en el comercio electrónico, el coste de cambio percibido presenta un efecto menos de-

terminante, lo que sugiere la necesidad de estrategias complementarias, como programas de lealtad, suscripciones o beneficios acumulativos, que fortalezcan el vínculo con el usuario. El estudio también reveló que la transparencia y la gestión ética de los datos personales influyen de forma significativa en la confianza digital. Aunque la preocupación por la privacidad no impide el uso de las plataformas, limita el grado máximo de fidelización alcanzable. Por tanto, la aplicabilidad de los algoritmos y la comunicación clara sobre el uso de datos se convierten en elementos esenciales para mantener la confianza y la continuidad del usuario. De manera general, los resultados permiten concluir que el BI predictivo, aplicado de forma responsable y ética, es una herramienta estratégica para incrementar la fidelización digital de la Generación Z, al proporcionar experiencias personalizadas, relevantes y confiables. Este hallazgo aporta evidencia empírica para la toma de decisiones organizacionales orientadas a la retención de usuarios jóvenes, optimización de contenidos y desarrollo de estrategias basadas en datos dentro de la economía digital.

Implicaciones prácticas

- Plataformas de streaming: mantener y comunicar de forma transparente la personalización, reforzando la percepción de control del usuario sobre sus recomendaciones.
- E-commerce: fortalecer la confianza mediante certificaciones de seguridad, políticas de privacidad claras y programas de fidelización que compensen la alta competencia.
- Fintech y servicios de entrega: implementar personalización prudente, con altos estándares de protección de datos y comunicación ética sobre el uso de información sensible.

La fidelización digital de la Generación Z depende no solo de la tecnología analítica utilizada, sino también de la capacidad institucional para equilibrar innovación, ética y experiencia del usuario. El BI predictivo, en este sentido, representa un instrumento clave para construir relaciones digitales sostenibles basadas en la confianza, la satisfacción y la relevancia continua.

Referencias bibliográficas

- Ahmad, M., Mustafa, M., Hamid, A., Khawaja, A., Zada, M., Jamil, A., Qaisar, S., Vega-Muñoz, A., Contreras-Barraza, N., & Anwer, A. (2022). Online customer experience leads to loyalty via customer engagement: Moderating role of value co-creation. *Frontiers in Psychology, 13*, 897851. <https://doi.org/10.3389/fpsyg.2022.897851>
- Cabrera, P., & González, A. (2022). Fidelización del cliente en el entorno digital: una revisión bibliográfica. *Revista de Ciencias Sociales (Ve)*, 28(2), 390–404.
- Chen, H., Li, J., & Wang, Y. (2022). Predictive analytics for business intelligence: A systematic review. *Information Systems Frontiers*.
- Choi, S., & Kim, J. (2024). *Validity and reliability of the Korean version of the digital burnout scale*. *Frontiers in Public Health, 12*. <https://doi.org/10.3389/fpubh.2024.1386394>
- George, D., & Mallery, P. (2019). IBM SPSS Statistics 26 step by step: A simple guide and reference. *Routledge*. <https://doi.org/10.4324/9780429056765>
- Guerra-Tamez, C. R., Kraul, H., Serna-Mendiburu, G. M., Chavelas, D., & Ibarra, J. (2024). Decoding Gen Z: AI's influence on brand trust and purchasing. *Frontiers in Artificial Intelligence*. <https://www.frontiersin.org/journals/artificial-intelligence/articles/10.3389/frai.2024.1323512/full>
- GhorbanTanhaei, H., et al. (2024). Predictive analytics in customer behavior: Anticipating customer decisions using machine learning. *Journal of Data-Driven Marketing*. <https://www.sciencedirect.com/science/article/pii/S2666720724000924>
- Hair, J., Black, W., Babin, B., & Anderson, R. (2021). *Multivariate data analysis* (8th ed.). Cengage.
- Kotler, P., & Keller, K. L. (2022). *Marketing management* (16th ed.). Pearson.
- Ko-Jen, H., Yesu, F., & Sudarshan, L. (2025). *Foundation model for personalized recommendation*. Netflix Tech Blog. <https://netflixtechblog.com/foundation-model-for-personalized-recommendation-1a0bd8e02d39>

- Lafuente, E., Ács, Z. J., & Szerb, L. (2022). Analysis of the digital platform economy around the world: A network DEA model for identifying policy priorities. *Journal of Small Business Management*, 62(2), 847–891. <https://doi.org/10.1080/00472778.2022.2100895>
- Lin, J. (2025). Application of machine learning in predicting consumer behavior and precision marketing. *PLOS ONE*, 20(5). <https://doi.org/10.1371/journal.pone.0321854>
- Mansoor, W., et al. (2024). Ethical challenges of predictive analytics in business intelligence. *Journal of Business Ethics*.
- Mauro, N., Hu, Z., & Ardissono, L. (2022). *Justification of recommender systems results: A service-based approach*. arXiv. <https://arxiv.org/abs/2211.03452>
- Martínez, P., & Lozano, D. (2022). Privacidad, confianza y ética en el uso de datos personales en plataformas digitales. *Revista Digital de Derecho Informático*, 7(15), 23–41.
- Mukhtar, S., Mohan, A. C., & Chandra, D. (2023). Exploring the influence of digital marketing on consumer behavior and loyalty. *International Journal of Multidisciplinary: Applied Business and Education Research*, 4(9), 3327–3339. <https://doi.org/10.11594/ijmaber.04.09.10>
- Pereira, M. d. S., de Castro, B. S., Cordeiro, B. A., de Castro, B. S., Peixoto, M. G. M., da Silva, E. C. M., & Gonçalves, M. C. (2025). Factors of customer loyalty and retention in the digital environment. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(2), 71. <https://doi.org/10.3390/jtaer20020071>
- Rana, A., Sanner, S., Bouadjenek, M. R., Carlantonio, R. D., & Farmaner, G. (2024). *User experience and the role of personalization in critiquing-based conversational recommender systems*. ACM Transactions on the Web. <https://rbouadjenek.github.io/papers/TWEB-22-0072.pdf>
- Roy, D., & Dutta, M. (2022). *A systematic review and research perspective on recommender systems*. Big Data Analytics. <https://doi.org/10.1186/s40537-022-00592-5>
- Oliver, R. L. (1999). Whence consumer loyalty? *Journal of Marketing*, 63(Special Issue), 33–44.
- Rane, N. L., Achari, A., & Choudhary, S. P. (2023). Enhancing customer loyalty through quality of service: Effective strategies to improve

- customer satisfaction, experience, relationship, and engagement. *International Research Journal of Modernization in Engineering Technology and Science*, 5(5). <https://doi.org/10.56726/IRJMETS38104>
- Sarker, I. H., et al. (2021). Machine learning for intelligent business analytics. *Information Systems Frontiers*, 23(3), 689–707.
- Sindhgatta, R., Ouyang, C., & Moreira, A. (2019). *Explaining process predictions using explainable AI techniques*. Proceedings of the International Conference on Business Process Management.
- Sánchez, J., & Rodríguez, D. (2021). Modelos de business intelligence para la fidelización del cliente en plataformas digitales. *Revista Iberoamericana de Innovación y Desarrollo Tecnológico*, 6(12), 55–73.
- Tristán-López, A. (2008). Modificación al modelo de Lawshe para el dictamen cuantitativo de la validez de contenido de un instrumento objetivo. *Avances en Medición*, 6(1), 37–48.
- The Rise of the Gen Z Consumer. (2023). ICSC Report. https://www.icsc.com/uploads/about/2023ICSC_Gen_Z_Report.pdf
- Theocharis, D., & Tsekouropoulos, G. (2025). Sustainable consumption and branding for Gen Z: How brand dimensions influence consumer behavior and adoption of newly launched technological products. *Sustainability*, 17(9), 4124. <https://doi.org/10.3390/su17094124>
- UNCTAD. (2023). *Informe sobre la economía digital 2023: Creación y captura de valor en América Latina*. Naciones Unidas.
- Van Dijk, P. (2024). AI-driven business intelligence for strategic decision-making. *International Journal of Information Management*.
- Wang, T., et al. (2025). Machine learning-based random forest prediction of online purchasing behavior. *ACM Transactions on Digital Commerce*. <https://dl.acm.org/doi/10.1145/3745133.3745186>
- Wu, M., Liu, W., Wang, Y., Ding, W., & Yao, M. (2025). *Rethinking user empowerment in AI recommender systems: Designing through transparency and control*. arXiv. <https://arxiv.org/abs/2509.11098>