

Análisis multivariado e interpretabilidad de modelos predictivos para la identificación de variables impulsoras del Net Promoter Score basado en encuestas de experiencia del cliente en el sector retail

Shirley Katherine Maldonado Meza

Informe de práctica para optar al título de Astrónoma

Asesoras
Olga Lopez Acevedo, Doctor (PhD)
Luz Esnedia Velásquez, Magíster (MSc)

Universidad de Antioquia
Facultad de Ciencias Exactas y Naturales
Astronomía
Medellín, Antioquia, Colombia
2026

Cita	(Maldonado Meza, 2026)
Referencia **Estilo APA 7 (2020)**	Maldonado Meza, S. (2026). *Análisis multivariado e interpretabilidad de modelos predictivos para la identificación de variables impulsoras del Net Promoter Score basado en encuestas de experiencia del cliente en el sector retail* [Informe de práctica]. Universidad de Antioquia, Medellín, Colombia.



Biblioteca Carlos Gaviria Díaz
Repositorio Institucional: http://bibliotecadigital.udea.edu.co
Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

A ti, Mirringa, que fuiste mi compañera durante el inicio de esta carrera, la compañera silenciosa de mis noches de estudio y la testigo de cada sueño que tomaba forma. Estuviste a mi lado en aquellos meses largos y solitarios en los que tu compañía se convirtió en mi refugio, tus ronroneos en consuelo y tu fidelidad en fuerza.

Por siempre, en mi memoria y en mi gratitud.

Agradecimientos

A mis padres, por apoyarme incondicionalmente en cada paso de este camino. A mis amigos, cuya compañía y aliento constante fueron un refugio en los momentos más difíciles de este proceso. A mis compañeros Mirringa, Kira y Sancocho, quienes con su presencia fiel y sus patitas suaves calentaron e iluminaron las noches de trabajo y renovando mi ánimo cuando más lo necesitaba.

A mi asesora, Olga López, por su guía experta, paciencia invaluable y orientación a lo largo de esta investigación.

A mi asesora del Grupo Éxito, Luz Velasquez, por haberme acogido con tanta generosidad en esta nueva experiencia, por compartir conmigo su conocimiento y por enseñarme tanto durante estos últimos meses.

Finalmente, quiero agradecer al Grupo Éxito, por brindarme la oportunidad de aprender y crecer en un entorno profesional tan enriquecedor, y por confiar en mi trabajo durante el desarrollo de este proyecto.

A todos, mi más sincero agradecimiento.

Índice

Resumen 10

Abstract 11

Introducción 12

1 Marco teórico 14

1.1 Medición de la experiencia del cliente y Net Promoter Score (NPS) 14

1.2 Moments of Truth (MoT) como estructura jerárquica de medición 15

1.3 Análisis descriptivo y exploratorio en variables ordinales 15

1.4 Análisis de Correspondencia Múltiple (ACM) 16

1.5 Reducción de dimensionalidad y Análisis de Componentes Principales (PCA) 17

1.6 Modelos predictivos no lineales y Gradient Boosting 18

1.7 Interpretabilidad: valores SHAP e importancia por permutación 20

1.8 Árboles de decisión y descubrimiento causal 21

2 Metodología 23

2.1 Enfoque general del análisis 23

2.2 Flujo de la encuesta y base de datos 23

2.3 Preparación de datos 26

2.4 Análisis Descriptivo 27

2.5 Análisis exploratorio de asociaciones entre variables 27

2.6 Análisis de Componentes Principales (PCA) 28

2.7 Modelamiento predictivo del NPS 29

2.8 Análisis de interpretabilidad: valores SHAP e importancia por permutación . 30
2.9 Árboles de decisión como herramienta interpretativa 31
2.10 Análisis de causalidad: algoritmo PC 32
3 Resultados. 33
3.1 Análisis Descriptivo: Generales 33
3.1.1 Distribuciones de calificación por MoT 37
3.2 Análisis Multivariado 38
3.2.1 Tablas de contingencia 38
3.2.2 Análisis de correspondencia múltiple 42
3.3 PCA 43
3.4 Desempeño de los modelos HGB, importancia de las variables e interpretabilidad 45
3.4.1 Nivel MoT → NPS 45
3.4.2 Nivel Aspectos → NPS 48
3.4.3 Desempeño del modelo regresor 53
3.5 Árboles de decisión 54
3.6 Algoritmo PC 59
4 Conclusiones 61
5 Recomendaciones 63
Referencias 64
Anexos 65

Lista de tablas

1 Resumen de preguntas incluidas en la encuesta con el código usado en la plataforma 25

2 Desempeño del modelo regresor 53

Lista de figuras

1 Flujo de la encuesta 26

2 Evolución anual del puntaje NPS e INS 33

3 Distribución de la clasificación NPS en el 2024 y 2025 para la omnicanalidad y tienda física 34

4 Distribución de la calificación INS en el 2024 y 2025 para la omnicanalidad y tienda física 35

5 Evolución mensual del NPS para la omnicanalidad y tienda física en el 2024 y 2025 36

6 Distribución del grupo NPS y NPS promedio por canal de compra 36

7 Distribución de la calificación para las preguntas del bloque de MoT 37

8 Tabla de contingencia para el segmento de clientes Éxito y NPS 38

9 Tabla de contingencia para el segmento de cliente Carulla y NPS 39

10 Tabla de contingencia para $Q3_3$ y NPS 40

11 Tabla de contingencia para $Q3_5$ y NPS 40

12 Análisis de correspondencia múltiple entre NPS y MoT 42

13 Contribución de los aspectos a la construcción del PCA de sus respectivos MoT 44

14 Convergencia del MoT y el PCA. 45

15 Matriz de confusión para el modelo clasificador 46

16 Importancia por permutación 47

17 Comparación de métricas de importancia de variables. 47

18 Importancia por permutación del bloque Búsqueda y Selección de pProductos 48

19 Impacto en el desempeño del modelo para la Búsqueda y Selección de Productos (SHAP) 48

20 Impacto en el desempeño del modelo para los Precios y Promociones (SHAP) 49

21 Importancia de permutación del bloque de Precios y Promociones (SHAP) . 49

22 Impacto en el desempeño del modelo para el bloque Aspecto del Sitio (SHAP) 50

23 Importancia de permutación del bloque de Aspectos del Sitio (SHAP) 50

24 Impacto en el desempeño del modelo para el bloque Pago de los Productos (SHAP) 51

25 Importancia de permutación del bloque de Pago de los Productos (SHAP) . 51

26 Impacto en el desempeño del modelo para el bloque Entrega de producto (SHAP) 52

27 Importancia de permutación del bloque de Entrega de producto (SHAP) . . 52

28 Árbol de decisión para los MoT. 54

29 Árbol de decisión para el bloque de Búsqueda y selección de productos. . . . 55

30 Árbol de decisión para el bloque de Precios y promociones. 56

31 Árbol de decisión para el bloque de Aspectos del sitio. 57

32 Árbol de decisión para el bloque de Proceso de pago. 57

33 Árbol de decisión para el bloque de entrega de productos. 58

34 DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando chi-square 59

35 DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando gcm 59

36 DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando pearson 60

Siglas, acrónimos y abreviaturas

ACM	Análisis de Correspondencia Múltiple
CES	Customer Effort Score
CX	Customer Experience
INS	Índice de Satisfacción
MoT	Momento de Verdad
NPS	Net Promoter Scor
PCA	Análisis de Componentes Principales

Resumen

Este trabajo analiza la influencia de los distintos aspectos de la experiencia de compra evaluados por el cliente sobre el Net Promoter Score (NPS) en un contexto de retail omnicanal, con el objetivo de identificar qué Momentos de Verdad (Moments of Truth, MoT) y variables especificas impactan con mayor intensidad en la lealtad del cliente. Para ello, se adopta un enfoque analítico que combina técnicas descriptivas, exploratorias y predictivas, permitiendo capturar la complejidad inherente a la experiencia del cliente. El análisis incluye una exploración descriptiva de las variables ordinales asociadas al NPS, los MoT y sus aspectos específicos, así como la aplicación de Análisis de Correspondencia Múltiple (ACM) para examinar las asociaciones entre las evaluaciones de los MoT y las categorías del NPS. Además, se emplea el Análisis de Componentes Principales (PCA) para evaluar la coherencia interna de los aspectos que componen cada MoT. En una etapa posterior, se construyen modelos predictivos no lineales basados en Gradient Boosting, complementados con técnicas de interpretabilidad como los valores SHAP y la importancia por permutación. Los resultados muestran una estructura clara de asociación entre bajas evaluaciones de los MoT y menores niveles de NPS, así como una correspondencia consistente entre calificaciones altas en ambos indicadores. El principal hallazgo del estudio indica que el MoT de *Entrega de productos* es el factor con mayor influencia sobre el NPS, posicionando la experiencia de entrega como un elemento determinante en la construcción de la lealtad del cliente.

Palabras clave: Experiencia del cliente; Net Promoter Score (NPS); Momentos de Verdad; análisis multivariado; Gradient Boosting; interpretabilidad de modelos; valores SHAP;

Abstract

This study analyzes the influence of different aspects of the shopping experience evaluated by customers on the Net Promoter Score (NPS) in an omnichannel retail context, with the Objective of identifying which Moments of Truth (MoT) and specific variables have the strongest impact on customer loyalty. To this end, an analytical approach is adopted that combines descriptive, exploratory, and predictive techniques, allowing the inherent complexity of the customer experience to be captured. The analysis includes a descriptive exploration of the ordinal variables associated with NPS, the MoT, and their specific aspects, as well as the application of Multiple Correspondence Analysis (MCA) to examine the associations between MoT evaluations and NPS categories. In addition, Principal Component Analysis (PCA) is employed to assess the internal coherence of the aspects composing each MoT. In a subsequent stage, non-linear predictive models based on Gradient Boosting are developed and complemented with interpretability techniques such as SHAP values and permutation importance. The results reveal a clear associative structure between low MoT evaluations and lower NPS levels, as well as a consistent correspondence between high scores in both indicators. The main finding of the study indicates that *Product Delivery* MoT is the factor with the greatest influence on NPS, positioning the delivery experience as a determining element in the construction of customer loyalty.

Keywords: Customer experience; Net Promoter Score (NPS); Moments of Truth; omnichannel retail; multivariate analysis; Gradient Boosting; model interpretability; SHAP values; customer loyalty; product delivery.

Introducción

La medición de la experiencia del cliente es una parte relevante dentro de los procesos analíticos orientados a comprender la percepción que tienen las personas sobre los servicios ofrecidos por una organización y el desempeño de estos. Las encuestas de experiencia son herramientas que sirven para capturar valoraciones, expectativas y niveles de satisfacción a lo largo del recorrido del cliente Lemon and Verhoef (2016). En el caso del Grupo Éxito, esta medición se realiza a través de encuestas de experiencia del servicio diseñadas por el área de Customer Experience (CX) y administradas a través de la plataforma Qualtrics, especializada en la recolección y análisis de información asociada a la experiencia del cliente. En este contexto, una de las métricas más utilizadas para analizar la evaluación del desempeño de los servicios es el Net Promoter Score (NPS), empleado como una métrica sintética que resume la disposición del cliente a recomendar la marca. Sin embargo, el NPS no se recolecta de forma aislada sino como parte de un instrumento más amplio que caracteriza de una forma más específica la experiencia del cliente.

La encuesta utilizada por el área de CX del Grupo Éxito posee una estructura jerárquica de dos niveles: un nivel agregado, correspondiente a los denominados Moments of Truth (MoT) que son etapas o interacciones dentro del recorrido de los clientes, y un nivel desagregado, compuesto por aspectos específicos asociados a cada uno de estos MoT, formulados como preguntas que indagan por características específicas de la experiencia. Además, los clientes le asignan una calificación directa a cada MoT, lo que permite contar con una valoración global de cada momento y como complemento, la información proveniente de los aspectos específicos.

Esta estructura permite capturar la experiencia del cliente desde un nivel global hasta niveles mucho más detallados, lo que podría brindar información sobre qué variables afectan la calificación global del NPS y de esta forma, poder tomar una ruta de acción que permita mejorar el desempeño general de la compañía. Sin embargo, su aplicación se da en un entorno operativo diverso donde las preguntas que conforman el nivel de aspectos pueden variar dependiendo del canal de compra y de los lugares de compra. Por ejemplo, un cliente cuya experiencia se limita a la compra en un canal digital puede recibir preguntas relacionadas con procesos de entrega, mientras que un cliente que interactúa en otros canales puede no estar expuesto a este tipo de ítems. Esta variabilidad en las preguntas implica que no todos los encuestados cuenten con el mismo conjunto de variables observadas, lo que añade heterogeneidad en la información y dificulta el procesamiento, la comparación directa y la agregación

de los datos.

Por esta razón, resulta pertinente examinar cómo influye la calificación de los MoT y sus aspectos específicos en el NPS y en qué medida, las calificaciones directas de los MoT constituyen una representación consistente de la información contenida en los aspectos que los componen. Sin una validación cuantitativa explícita, no es evidente si ambas representaciones son analíticamente equivalentes o si, por el contrario, presentan diferencias relevantes en su capacidad para describir la percepción global del cliente.

El presente trabajo tiene como objetivo realizar un análisis descriptivo y predictivo de la información proveniente de las encuestas, con el fin de extraer insights relevantes que apoyen la toma de decisiones del Grupo Éxito. También se busca identificar cuáles de los aspectos evaluados en los distintos MoT muestran una mayor asociación con la calificación del NPS con el propósito de comprender qué dimensiones tienen un mayor peso en la percepción global. Además, se pretende analizar el grado de correspondencia entre la evaluación general de los MoT y las calificaciones dadas a sus aspectos específicos con el fin de evaluar la coherencia interna de la medición y su utilidad como herramienta analítica.

Finalmente, este trabajo se centra en el contexto de la omnicanalidad considerando las experiencias asociadas a los canales digitales y remotos, y excluyendo el canal físico. Esta delimitación responde tanto a las características del conjunto de datos disponible como a la necesidad de analizar de forma coherente experiencias que comparten dinámicas operativas similares pero que, al mismo tiempo, mantienen una alta diversidad en los momentos evaluados.

1 Marco teórico

1.1 Medición de la experiencia del cliente y Net Promoter Score (NPS)

Desde un punto de vista analítico, la experiencia del cliente puede entenderse como un constructo latente: una síntesis de percepciones, evaluaciones racionales y respuestas emocionales que se van formando a lo largo de las distintas interacciones entre el cliente y la organización Lemon and Verhoef (2016). Esta naturaleza acumulativa hace que la medición no sea trivial y que cualquier indicador aislado solo capture una parte del fenómeno.

Dentro de este contexto, el Net Promoter Score (NPS) es una de las métricas ampliamente utilizadas para aproximarse a la lealtad del cliente y a su disposición a recomendar una marca. El NPS se obtiene a partir de una escala ordinal de 0 a 10, en la que los clientes se agrupan en Detractores (0–6), Pasivos (7–8) y Promotores (9–10). Más allá de su aparente simplicidad, desde la estadística resulta fundamental reconocer que el NPS no es simplemente un promedio ni una proporción agregada, sino una variable ordinal categorizada que refleja una decisión latente de recomendación futura Reichheld (2003).

Precisamente por este carácter sintético el NPS tiende a ocultar información relevante sobre los factores que explican dicha calificación. Saber que el NPS es alto o bajo dice poco sobre qué aspectos concretos de la experiencia están influyendo en esa percepción. Por esto es que analizar el NPS de manera aislada suele ser insuficiente para orientar decisiones estratégicas. La literatura en marketing analítico y customer analytics insiste en la necesidad de descomponer la experiencia en componentes observables que permitan identificar con mayor precisión dónde intervenir y cómo priorizar acciones de mejora Fader and Hardie (2009)

En esta línea, métricas complementarias como el Índice de Satisfacción (INS) o el Customer Effort Score (CES) aportan información adicional sobre dimensiones específicas de la experiencia aunque estas siguen siendo evaluaciones globales. El verdadero potencial analítico aparece cuando estas métricas se articulan con mediciones más detalladas como por ejemplo, las evaluaciones de los Momentos de Verdad (Moments of Truth, MoT) y de los aspectos particulares que los componen.

1.2 Moments of Truth (MoT) como estructura jerárquica de medición

Los Moments of Truth representan aquellas etapas del recorrido del cliente en las que se definen, refuerzan o deterioran sus percepciones sobre el servicio recibido. No todos los momentos tienen el mismo peso ni generan el mismo impacto emocional, y precisamente ahí radica su interés analítico. Conceptualmente, los MoT pueden entenderse como una estructura jerárquica de medición, en la que cada momento sintetiza la evaluación de un conjunto de atributos o aspectos específicos que describen la experiencia vivida.

Desde el punto de vista estadístico, esta estructura introduce una relación claramente multinivel: los aspectos específicos se encuentran anidados dentro de cada MoT, y estos, a su vez, se relacionan con el NPS como variable objetivo. Este diseño permite analizar la experiencia tanto desde una perspectiva agregada como desde un nivel más fino de detalle, pero también plantea retos metadológicos. Entre ellos se encuentran la heterogeneidad en las respuestas, la presencia de valores faltantes de tipo estructural y la alta correlación entre variables que describen experiencias similares.

La investigación en calidad del servicio y experiencia del cliente ha mostrado que las evaluaciones globales no siempre se explican de manera directa ni lineal a partir de sus componentes observables Parasuraman et al. (1988). Esto implica que no basta con asumir que mejorar un atributo específico se traducirá automáticamente en una mejor evaluación global. En consecuencia, se hace necesario recurrir a herramientas estadísticas multivariadas que permitan evaluar empíricamente la coherencia interna de esta jerarquía y su relación con indicadores de lealtad como el NPS.

1.3 Análisis descriptivo y exploratorio en variables ordinales

El análisis descriptivo es el punto de partida natural en estudios basados en encuestas, sobre todo cuando las variables involucradas son de naturaleza ordinal y categórica, como ocurre con el NPS, los MoT y sus aspectos específicos. A diferencia de las variables continuas, las escalas ordinales preservan un orden entre categorías, pero no garantizan que las distancias entre ellas sean comparables, lo que limita el uso directo de estadísticos clásicos que dependen de supuestos de normalidad o intervalos equidistantes Agresti (2010).

Por esta razón, el análisis descriptivo se apoya principalmente en distribuciones de frecuencia, comparaciones entre grupos y medidas de posición robustas. Este tipo de exploración

permite detectar patrones generales, concentraciones de respuestas y posibles asimetrías en la percepción de la experiencia. En un contexto empresarial, estos resultados suelen ser especialmente útiles para identificar señales tempranas de deterioro, como desplazamientos hacia categorías bajas del NPS o aumentos sostenidos en la proporción de detractores.

No obstante, este nivel de análisis tiene limitaciones claras, pues si bien ofrece una primera aproximación al comportamiento de los datos, no permite capturar relaciones simultáneas entre múltiples variables ni explorar asociaciones más complejas, lo que justifica el uso de técnicas exploratorias multivariadas.

1.4 Análisis de Correspondencia Múltiple (ACM)

El Análisis de Correspondencia Múltiple (ACM) es una técnica factorial diseñada específicamente para explorar asociaciones entre variables categóricas y ordinales mediante su representación en un espacio de baja dimensión Greenacre (2017). Desde una perspectiva algebraica, el ACM se basa en la descomposición de la inercia total de una matriz disyuntiva completa, lo que permite identificar dimensiones latentes que resumen las principales estructuras de asociación presentes en los datos.

A diferencia de enfoques paramétricos, el ACM no impone supuestos de linealidad ni normalidad, lo que lo hace particularmente adecuado para el análisis de encuestas de experiencia del cliente. En el contexto de este trabajo, el ACM permite visualizar de manera intuitiva cómo las distintas calificaciones de los MoT se relacionan con las categorías del NPS, revelando agrupamientos de comportamiento que no son evidentes un análisis univariado.

La interpretación de las distancias en el plano factorial facilita la identificación de MoT que se asocian de forma consistente con evaluaciones extremas del NPS. Este tipo de evidencia exploratoria resulta valiosa, ya que aporta una base empírica para el uso posterior de modelos predictivos, al mostrar que las relaciones entre MoT y NPS presentan una estructura clara y que no responden a patrones aleatorios.

1.5 Reducción de dimensionalidad y Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales (PCA) es una técnica clásica de reducción de dimensionalidad cuyo objetivo es representar un conjunto de variables correlacionadas mediante un número reducido de componentes ortogonales que concentran la mayor parte de la varianza total Jolliffe and Cadima (2016). Su uso es habitual cuando se trabaja con cuestionarios extensos que incluyen múltiples ítems relacionados entre sí.

El PCA transforma un conjunto de variables correlacionadas en un conjunto de variables nuevas *linealmente independientes* llamadas **componentes principales**. Cada componente principal es una combinación lineal de las variables originales.

- El primer componente principal (PC1) captura la mayor varianza posible de los datos.
- El segundo componente (PC2) captura la mayor varianza posible que no esté explicada por PC1.
- Todos los componentes son *ortogonales* entre sí, es decir, no están correlacionados.

Ahora, supongamos que tenemos un conjunto de datos con n observaciones y p variables. El proceso para aplicar el PCA es el siguiente:

1. **Centrar los datos:** Se restan las medias de cada variable para que tengan media cero:

$$X_{\text{centrado}} = X - \bar{X}$$

2. **Calcular la matriz de covarianza:**

$$\Sigma = \frac{1}{n-1} X_{\text{centrado}}^T X_{\text{centrado}}$$

   Esta matriz mide cómo varían las variables entre sí y captura sus correlaciones.

3. **Descomposición en vectores y valores propios:** Se resuelve:

$$\Sigma v = \lambda v$$

   donde v son los *vectores propios* (direcciones de los componentes principales) y λ son los *valores propios* (cuánta varianza explica cada componente).

4. **Ordenar los componentes:** Se ordenan los vectores propios según sus valores propios de mayor a menor. Los primeros k vectores forman la base de los componentes principales que retienen la mayor parte de la varianza.

5. **Proyección de los datos:** Los datos originales se proyectan sobre estos vectores propios:

$$Z = X_{\text{centrado}} V_k$$

donde Z son los datos transformados y V_k contiene los k vectores propios seleccionados.

Cada componente principal es una combinación lineal de las variables originales con cargas (loadings) que indican la contribución de cada variable. El valor propio asociado a cada componente indica la proporción de varianza del dataset original que captura. Manteniendo solo los primeros componentes se logra reducir dimensionalidad, simplificar modelos, visualizar datos o eliminar ruido, perdiendo información mínima.

En este estudio, el PCA se utiliza con un propósito claramente instrumental: construir representaciones latentes de los MoT a partir de sus aspectos específicos, mitigando problemas de multicolinealidad y alta dimensionalidad. Conviene subrayar que el PCA no se plantea como un modelo explicativo del NPS ni como una herramienta causal, sino como un recurso para evaluar la coherencia interna de los bloques de aspectos y su correspondencia con las evaluaciones globales de cada MoT.

Desde un análisis estadístico, el hecho de que el primer componente concentre una proporción considerable de la varianza sugiere la existencia de una dimensión latente común dentro de cada MoT. Sin embargo, las correlaciones moderadas o bajas entre estas representaciones latentes y las calificaciones directas de los MoT indican que las evaluaciones globales capturan información adicional, posiblemente asociada a factores subjetivos o contextuales que no están completamente reflejados en los aspectos medidos. Este hallazgo refuerza la necesidad de analizar ambos niveles de información de manera complementaria.

1.6 Modelos predictivos no lineales y Gradient Boosting

El análisis predictivo del NPS se aborda mediante algoritmos de Gradient Boosting, en particular Histogram Gradient Boosting, que pertenecen a la familia de modelos ensamblados basados en árboles de decisión Friedman (2001). Estos modelos resultan adecuados para

datos tabulares con variables ordinales y relaciones complejas, características habituales en encuestas de experiencia del cliente.

Histogram-based Gradient Boosting es una variante del **Gradient Boosting**, un método de ensamble basado en árboles de decisión. La idea central de Gradient Boosting es combinar muchos árboles pequeños (débilmente predictivos) de manera secuencial, donde cada árbol intenta corregir los errores del anterior. La versión *histogram-based* optimiza la construcción de los árboles agrupando los valores de cada característica en **bins** (intervalos discretos), lo que reduce significativamente el tiempo de entrenamiento, especialmente con datasets grandes.

El algoritmo de este modelo es el siguiente: Supongamos que queremos predecir una variable y usando un conjunto de predictores X.

1. **Función de pérdida:** Se define una función de pérdida $L(y, \hat{y})$, como el error cuadrático medio para regresión o la log-loss para clasificación.

2. **Inicialización:** Se comienza con un modelo inicial $\hat{y}^{(0)}$ que minimiza la pérdida:

$$\hat{y}^{(0)} = \arg\min_{\gamma} \sum_{i=1}^{n} L(y_i, \gamma)$$

3. **Iteración para cada árbol:** Para $m = 1, \ldots, M$ (donde M es el número de árboles):

   a) Se calcula los *residuos negativos de la función de pérdida* (gradientes):

$$r_i^{(m)} = -\left[\frac{\partial L(y_i, \hat{y}_i^{(m-1)})}{\partial \hat{y}_i^{(m-1)}}\right]$$

   b) Se ajusta un árbol $h_m(X)$ a estos residuos.

   c) Se actualiza la predicción:

$$\hat{y}^{(m)} = \hat{y}^{(m-1)} + \eta\, h_m(X)$$

   donde η es la tasa de aprendizaje (*learning rate*).

4. **Histograma de características:** Antes de construir cada árbol, cada característica se divide en *bins* discretos. El árbol se construye considerando solo estos bins en lugar de cada valor continuo, lo que reduce la complejidad computacional al buscar los puntos de corte óptimos.

Cada árbol intenta aproximar el gradiente de la función de pérdida, lo que equivale a realizar un descenso de gradiente en el espacio de funciones. La combinación secuencial de árboles produce un modelo final que minimiza la pérdida global. La discretización mediante histogramas acelera el entrenamiento y actúa como una ligera regularización, reduciendo el sobreajuste. Este método es eficiente en datasets grandes con variables numéricas continuas, manteniendo precisión mientras disminuye el costo computacional.

El uso combinado de modelos de clasificación y regresión permite analizar el NPS desde dos ángulos complementarios: por un lado, la segmentación estratégica entre promotores y detractores; por otro, la variación continua en la evaluación de la experiencia. Esta doble aproximación enriquece la interpretación de los resultados y amplía su utilidad para la toma de decisiones.

1.7 Interpretabilidad: valores SHAP e importancia por permutación

Dado que los modelos de boosting presentan una estructura compleja, su aplicación práctica requiere herramientas que permitan interpretar sus resultados de forma transparente. Los valores SHAP (SHapley Additive exPlanations) se apoyan en la teoría de juegos cooperativos y ofrecen una descomposición aditiva de la predicción en contribuciones individuales de cada variable Lundberg and Lee (2017). Los valores SHAP permiten analizar tanto efectos globales como locales, manteniendo propiedades de consistencia y equidad en la asignación de importancia.

Sea un modelo $f(x)$ y un conjunto de características $x = (x_1, x_2, \ldots, x_p)$. El valor SHAP de la característica j se define como:

$$\phi_j = \sum_{S \subseteq \{1,\ldots,p\} \setminus \{j\}} \frac{\mathtt{S}!(p - \mathtt{S} - 1)!}{p!} \left[f_{S \cup \{j\}}(x_{S \cup \{j\}}) - f_S(x_S) \right]$$

donde S es un subconjunto de características y $f_S(x_S)$ es la predicción usando solo las características en S.

La suma de todos los valores SHAP y la predicción base ϕ_0 reproduce la predicción del modelo:

$$f(x) = \phi_0 + \sum_{j=1}^{p} \phi_j$$

Cada ϕ_j mide la contribución promedio de la característica considerando todas las

combinaciones posibles. SHAP permite explicar modelos complejos tanto de manera local (por predicción) como global (promediando valores SHAP). Lundberg and Lee (2017)

Importancia por permutación

De manera complementaria, la importancia por permutación evalúa el impacto de cada variable sobre el desempeño predictivo del modelo, proporcionando una medida robusta basada en el deterioro del error.

La importancia por permutación evalúa cuánto disminuye la precisión de un modelo cuando se permuta aleatoriamente una característica. Si permutar una característica no cambia la predicción, su importancia es baja; si la predicción empeora significativamente, la característica es importante.

Sea un modelo $f(x)$ entrenado y un conjunto de datos de prueba X con predicciones $f(X)$. Para cada característica j:

1. Se permutan aleatoriamente los valores de x_j obteniendo X_j^{perm}.
2. Se calcula la métrica de desempeño M (error, log-loss, AUC):

$$I_j = M(f(X_j^{\text{perm}}), y) - M(f(X), y)$$

Valores mayores de I_j indican mayor importancia de la característica.

La importancia por permutación es independiente del modelo (*model-agnostic*) y refleja la dependencia empírica del modelo en cada característica, siendo útil para detectar variables que realmente afectan la predicción.

La combinación de ambos enfoques refuerza la credibilidad de los resultados y facilita la identificación de variables que no solo están asociadas al NPS, sino que influyen activamente en su comportamiento dentro del modelo.

1.8 Árboles de decisión y descubrimiento causal

Los árboles de decisión se emplean como herramientas interpretativas que permiten extraer reglas claras y fácilmente comunicables, especialmente útiles cuando los resultados deben ser compartidos con audiencias no técnicas. Aunque su capacidad predictiva suele

ser inferior a la de los modelos ensamblados, su fortaleza radica en la claridad con la que representan relaciones jerárquicas entre variables Hastie (2009).

Finalmente, el algoritmo PC se incorpora como una herramienta exploratoria para el descubrimiento de relaciones causales en datos observacionales. Basado en pruebas de independencia condicional, este algoritmo permite proponer grafos causales bajo supuestos estándar de causalidad Pearl (2000). En el marco de este trabajo, sus resultados se interpretan con cautela, como hipótesis causales plausibles y no como afirmaciones definitivas, lo que es coherente con la complejidad y las limitaciones inherentes al análisis causal en contextos no experimentales.

2 Metodología

2.1 Enfoque general del análisis

El presente trabajo se desarrolla bajo un enfoque cuantitativo aplicado, con un alcance descriptivo, exploratorio y predictivo, orientado al análisis de encuestas de satisfacción de clientes en un contexto empresarial del sector retail con operación omnicanal. El objetivo central del estudio es identificar y analizar los factores que influyen en el NPS.

La metodología adoptada no se limita a la predicción del NPS, sino que busca comprender de manera estructurada cómo distintos niveles de la experiencia del cliente (aspectosespecíficos y MoT) se relacionan con dicho indicador. Para ello, se implementa una estrategia analítica que combina técnicas estadísticas multivariadas y modelos de aprendizaje automático, priorizando tanto el desempeño predictivo como la interpretabilidad de los resultados.

2.2 Flujo de la encuesta y base de datos

Los datos analizados provienen de respuestas diligenciadas por clientes tras completar el proceso de compra, esta se envía a los clientes a través del correo electrónico, 1 o 2 días después de realizada de una compra por cualquiera de los canales disponibles. Los datos obtenidos fueron modificados con el fin de mantener la privacidad de la información.

La encuesta inicia con la pregunta del NPS, utilizada como variable objetivo principal del estudio: "Basado en esta experiencia de compra ¿Qué tan probable es que recomiendes a un amigo o familiar Marca evaluada?", esta es una variable ordinal que se mide del 0 al 10 siendo 0=Nada probable y 10=Muy probable. Luego, salta a la pregunta INS "¿Qué tan satisfecho quedaste con tu compra en Marca evaluada?" con una escala categórica que va desde 'Muy insatisfecho' (peor nota) hasta 'Muy satisfecho' (mejor nota).

Luego de estas preguntas iniciales, se le solicita al cliente evaluar cómo se sintió respecto a ciertos aspectos de la compra; aquí, se presenta una matriz donde las filas son cada MoT y las columnas es la del nivel de satisfacción; de igual forma, se solicita una calificación de cada uno los aspectos específicos de sólo un MoT (el sistema selecciona de forma aleatoria el MoT a evaluar). Finalmente, se realizan las preguntas CES de compra y pago. Estas son respectivamente '¿Qué tan fácil fue el proceso de compra?' y '¿Qué tan fácil fue el proceso de pago?'.

Por cada encuesta realizada, solamente se tiene un bloque de aspectos calificado, correspondiente a un único MoT, el cual es seleccionado de manera aleatoria por la plataforma cumpliendo con las características de la compra. En consecuencia, la base de datos resultante presenta una estructura incompleta por diseño, en la que no todos los encuestados evalúan la totalidad de los aspectos asociados a cada MoT. Esta característica del instrumento implica que la información disponible para los aspectos específicos de cada MoT se encuentra distribuida de forma no uniforme entre los registros generando una matriz de datos con valores faltantes estructurales. Dichos valores no responden a omisiones del encuestado, sino a la lógica de aplicación de la encuesta, por lo que su tratamiento requiere consideraciones metodológicas particulares en las etapas posteriores del análisis.

A partir de las respuestas recolectadas, se construyó una base de datos consolidada en la que se integran: la calificación NPS, las evaluaciones de los MoT y los aspectos específicos asociados a cada MoT, y las métricas CES de compra y de pago. Cada registro corresponde a una experiencia de compra individual, asociada a un único cliente y a un único momento temporal.

Como datos embebidos dentro de la encuesta (datos que se tienen en el registro general del cliente) también se tiene información del cliente y de la compra que se realizó y que derivó en el envío de la encuesta. Los datos son:

- La segmentación del Éxito o Carulla a la que pertenece el cliente (en caso de que aplique).
- La cadena más frecuentada por el cliente, estas pueden ser: Éxito, Carulla, Surtimax, SuperInter y Surtimayorista.
- Canal por el que realizó la compra.

Para facilitar la comprensión de esta lógica de ramificación y los bloques de información resultantes, el flujo de la encuesta se presenta a continuación

Tabla 1

Resumen de preguntas incluidas en la encuesta con el código usado en la plataforma

Código de pregunta	Pregunta	Bloque
Q1_int	Basado en esta experiencia de compra ¿Qué tan probable es que recomiendes a un amigo o familiar Marca evaluada?	Q1
Q11_int	Qué tan fácil fue realizar el pago?	Q11
Q124_int	Qué tan fácil fue el proceso de compra?	Q124
Q3_1_int	Búsqueda y selección de tus productos	Q3
Q3_2_int	Precios y promociones de tus productos	Q3
Q3_3_int	Realizando tu compra en [Field-CanalEnunciado]	Q3
Q3_4_int	Momento del pago	Q3
Q3_5_int	Entrega de tus productos	Q3
Q1_1_int	Claridad en el precio	Q1
Q1_2_int	Facilidad para encontrar los productos	Q1
Q1_3_int	Disponibilidad del producto deseado	Q1
Q1_4_int	Calidad y frescura de los productos	Q1
Q1_5_int	Variedad de los productos	Q1
Q1_7_int	Claridad en promociones y descuentos	Q1
Q1_8_int	Calidad de los productos	Q1
Q5_1_int	Claridad en promociones y descuentos	Q5
Q5_2_int	Productos de Marcas Propias que brindan una opción	Q5
Q5_3_int	Encontró productos que se ajustan a su presupuesto	Q5
Q5_5_int	Precios que se ajustan a mi presupuesto	Q5
Q5_7_int	Calidad y disponibilidad de productos de marca	Q5
Q5_9_int	Descuentos y promociones atractivos	Q5
Q7_1_int	Amabilidad y disposición del personal que te atendió	Q7
Q7_2_int	Limpieza y orden del almacén	Q7
Q7_3_int	Facilidad de uso del sitio	Q7
Q7_4_int	Tiempo de respuesta	Q7
Q7_5_int	Conocimiento del personal	Q7
Q7_6_int	Claridad en la información sobre los productos	Q7
Q7_7_int	Información oportuna respecto a disponibilidad	Q7
Q7_10_int	Claridad en los pasos a seguir para realizar la compra	Q7
Q8_1_int	Coherencia entre el precio exhibido y el precio final	Q8
Q8_2_int	Tiempo requerido para hacer el pago	Q8
Q8_3_int	Facilidad al momento de pagar	Q8
Q8_6_int	Medios de pago disponibles	Q8
Q9_1_int	Estado y presentación de los productos	Q9
Q9_2_int	Cumplimiento en los tiempos de entrega	Q9
Q9_3_int	Pedido completo	Q9
Q9_4_int	Amabilidad del personal que entregó tu pedido	Q9

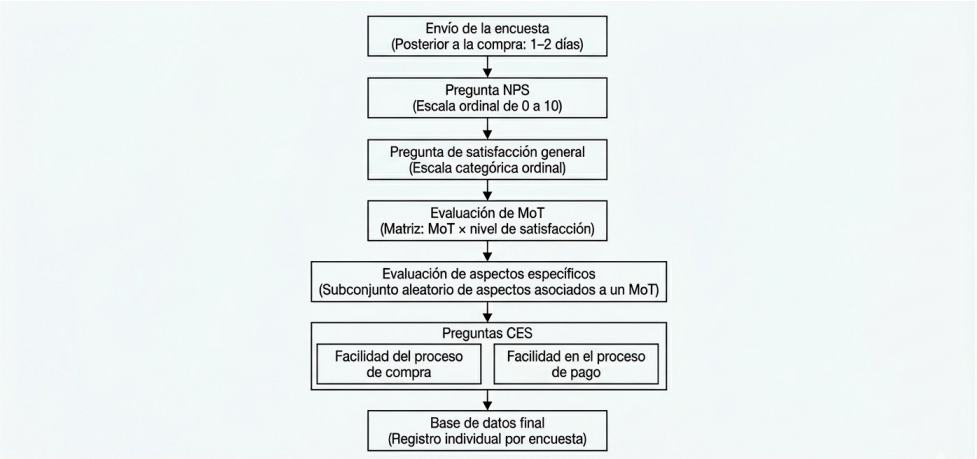

Figura 1

Flujo de la encuesta

Esta estructura constituye la base sobre la cual se desarrollan los análisis descriptivos, multivariados y predictivos presentados en las secciones siguientes, además, condiciona tanto la selección de las técnicas estadísticas empleadas como la interpretación de los resultados obtenidos. Finalmente, como los datos recolectados están representado por códigos dentro de la encuesta, la correspondencia completa entre códigos, preguntas y dimensiones evaluadas se presentan en la tabla 1.

2.3 Preparación de datos

Previo a la aplicación de las técnicas estadísticas y de aprendizaje automático, se realizó la preparación y depuración de los datos con el fin de garantizar la coherencia, comparabilidad y validez analítica de la información recolectada. Este proceso incluyó la selección de registros válidos, la estandarización de escalas y la transformación de variables categóricas en representaciones numéricas adecuadas para el análisis computacional. Las calificaciones asociadas a los MoT y a los aspectos específicos fueron tratadas como variables categóricas ordinales y posteriormente codificadas numéricamente respetando el orden inherente de las escalas de satisfacción.

Adicional a esto, respondiendo al objetivo planteado por la compañía, se seleccionaron aquellas encuestas realizadas desde el 1 de enero de 2025 hasta el 30 de noviembre del mismo año. Además, se hizo una separación de las encuestas cuyas compras fueron realizadas en la omnicanalidad y en las tiendas físicas.

2.4 Análisis Descriptivo

El análisis descriptivo se empleó como una etapa inicial de exploración de datos con el fin de caracterizar la información recolectada, evaluar su estructura y comprender su comportamiento general antes de aplicar técnicas y modelos estadísticos. En este punto, se identificaron patrones básicos y la distribución de las calificaciones otorgadas por los encuestados.

Debido a la naturaleza de las variables, el análisis descriptivo se centró en el cálculo de frecuencias absolutas y relativas, medidas de tendencia central y medidas de dispersión. Para las variables categóricas, se analizaron distribuciones univariadas que permitieran observar la concentración de respuestas en cada aspecto evaluado (MoT, aspectos específicos, INS y CES).

Con el NPS, se analizó la distribución de clientes Promotores, Pasivos y Detractores y se realizó una comparación anual y entre la omnicanalidad y la tienda física. Adicionalmente, se analizaron por separado las distribuciones de la calificación original del NPS para conservar información sobre la variabilidad de las respuestas y facilitar comparaciones posteriores con otras variables del estudio. Además, se realizó el cálculo del NPS con la ecuación —— para ver la evolución del NPS en los últimos 2 años tanto para la omnicanalidad como para la tienda física.

2.5 Análisis exploratorio de asociaciones entre variables

Una vez caracterizada la información, se realizó el análisis de las relaciones entre las distintas preguntas de la encuesta. Esta etapa tuvo como propósito identificar asociaciones preliminares entre el NPS, los MoT, los aspectos específicos y el INS y CES sin imponer supuestos de causalidad.

En un primer acercamiento, se construyeron tablas de contingencia entre pares de variables categóricas y ordinales, específicamente entre el NPS y las calificaciones del MoT, NPS y aspectos específicos y el MoT con los aspectos que este abarca. Estas tablas permitieron observar la distribución conjunta de las respuestas y explorar cómo se concentran las categorías de una variable en función de la otra. Para facilitar la interpretación, se trabajó con frecuencias relativas, lo que permitió comparar patrones entre variables con distintos tamaños muestrales.

Posteriormente, con el fin de sintetizar estas relaciones y explorar la estructura global de asociación entre múltiples variables categóricas ordinales de manera simultánea, se aplicó un análisis de correspondencia múltiple (ACM). Este se llevó a cabo utilizando la plataforma SAS, considerando solamente las variables MoT y las calificaciones del NPS. Esta técnica se aplicó específicamente sobre las evaluaciones de los MoT y las calificaciones del NPS. Para ello, se construyó la matriz disyuntiva completa a partir de las categorías observadas y se obtuvo una representación factorial que sintetiza las principales asociaciones entre dichas variables. Este procedimiento permitió reducir la complejidad del espacio categórico y facilitó la exploración visual y analítica de las relaciones entre los distintos MoT y el NPS, sin imponer suposiciones de linealidad o normalidad sobre los datos.

2.6 Análisis de Componentes Principales (PCA)

Finalizado el análisis descriptivo y relacional, se construyeron representaciones de los MoT a partir de la información de los aspectos específicos que los componen usando el Análisis de Componentes Principales. Este se aplicó de manera independiente para cada MoT considerando solamente las preguntas asociadas a dicho momento.

Como cada encuestado califica únicamente un subconjunto de aspectos, los datos contienen bloques desbalanceados en donde algunos aspectos cuentan con más respuestas que otros (sobre todo aquellos en los que se califica sólo al comprar en una de las cadenas o por uno de los canales). Para corregir esto, se excluyeron aquellos aspectos con poco número de respuestas que afectaban la estabilidad de la muestra, disminuía notablemente el número de respuesta de otros aspectos y aportaban poca información al momento de construir el PCA. Así, se trabajó con cierto número de respuestas válidas mínimas asociadas a cada aspecto, de tal forma que se pudo construir una matriz que reflejara la participación relativa de cada ítem dentro del MoT que le corresponde. Aquellas preguntas con pocas respuestas fueron eliminadas para la construcción del PCA pues, si llegaban a ser incluidas, habría bloques con muy pocas respuestas (menos de 100). Este balanceo permitió generar una base comparable entre aspectos para la construcción del PCA.

Luego, con los aspectos resultantes, se calculó la puntuación asociada a cada observación que se interpretó como una representación latente de cada MoT. Posteriormente, estas representaciones se compararon con las calificaciones directas de los MoT hechas por lo clientes mediante el análisis de correlaciones con el propósito de evaluar el grado de correspondencia entre ambas formas de medición.

Es importante destacar que el PCA no se utiliza en este estudio como un modelo explicativo del NPS ni como una herramienta de inferencia causal. Su función es estrictamente instrumental: reducir la complejidad del espacio de variables y facilitar el análisis posterior, evitando problemas derivados de la multicolinealidad y la alta dimensionalidad.

Este paso permitió observar la coherencia entre el nivel desagregado de los aspectos y el nivel agregado de los MoT desde una perspectiva empírica, manteniendo una separación clara entre la construcción de las representaciones latentes y los análisis posteriores orientados a modelar la relación con el NPS.

2.7 Modelamiento predictivo del NPS

En este paso, se realizó el modelamiento predictivo del NPS con el objetivo de estudiar, ahora sí, la relación entre las calificaciones de la experiencia del cliente y el NPS. Esta fase se desarrolló utilizando principalmente las librerías *scikit-learn, NumPy y pandas*, utilizadas en análisis estadístico y aprendizaje automático.

La aplicación y entrenamiento de estos modelos se realiza en 2 niveles: el primer nivel es MoT→NPS y el segundo, aspecto del MoT → MoT, tomándose la segunda variable como la variable dependiente en ambos casos. Para estos niveles, se aplicaron modelos de *Histogram Gradient Boosting* previamente entrenados según el objetivo de cada nivel.

Para el primer nivel, los MoT fueron utilizados como variables explicativas para modelar la calificación del NPS. En el segundo nivel, los aspectos específicos asociados a cada MoT se emplearon como predictores de la calificación directa de dicho MoT. Esta diferenciación permitió analizar la estructura de la encuesta de manera jerárquica y coherente con su diseño original.

Específicamente en el primer nivel, se planteó un problema de clasificación y se entrenó el modelo *HistGradientBoostingClassifier*, cuyo objetivo es estimar la probabilidad de pertenencia de cada cliente a dichas categorías. Este enfoque es relevante desde el punto de vista empresarial, ya que las decisiones estratégicas suelen basarse en la segmentación de clientes según el NPS. El desempeño del modelo se evaluó mediante métricas de clasificación como *accuracy, ROC AUC y F1-score* y métricas basadas en la comparación entre las etiquetas reales y las predicciones del modelo como la *matriz de confusión*.

Para la predicción del segundo nivel, en cada bloque, se usó el mismo modelo pero, en

este caso, las categorías serían la evaluación del 1 al 5 tanto de los MoT como de los aspectos específicos. Adicionalmente, se implementó el modelo *HistGradientBoostingRegressor* en el que no se toman las calificaciones como categorías, sino como una variable numérica continua.

Previo al entrenamiento de los modelos, los conjuntos de datos se dividieron en subconjuntos de entrenamiento y prueba mediante la función *train_test_split*, asegurando que la evaluación del desempeño se realizara sobre observaciones no utilizadas durante el ajuste del modelo. Este procedimiento permitió reducir el riesgo de sobreajuste y facilitar comparaciones consistentes entre los distintos modelos implementados.

El entrenamiento de los modelos se llevó a cabo utilizando los hiperparámetros por defecto de la librería priorizando la estabilidad del procedimiento y la reproducibilidad de los resultados.

Esta etapa de modelamiento se concibió como un paso necesario para comprender la relación entre las variables de experiencia y el NPS desde un enfoque multivariado y no lineal. Más allá del desempeño predictivo, los modelos entrenados sirvieron como base para el análisis posterior de interpretabilidad que está orientado a identificar qué elementos de la experiencia del cliente tienen una mayor influencia sobre las predicciones del NPS, aspecto que se desarrolla en la subsección siguiente.

2.8 Análisis de interpretabilidad: valores SHAP e importancia por permutación

Para comprender el comportamiento de los modelos predictivos entrenados y evitar interpretaciones basadas únicamente en métricas de desempeño, se incorporaron técnicas de interpretabilidad orientadas a identificar la contribución relativa de cada variable. Este análisis se desarrolló utilizando principalmente las librerías shap y scikit-learn y se aplicó de en los dos niveles analíticos: el nivel MoT $\rightarrow$ NPS y el nivel aspectos $\rightarrow$ MoT.

El análisis de interpretabilidad se inició con el cálculo de valores SHAP al emplear la clase *TreeExplainer* que es la adecuada para modelos basados en árboles. Para cada modelo, los valores SHAP se calcularon utilizando el conjunto de datos de prueba de tal forma que las interpretaciones se basaran en observaciones no utilizadas durante el entrenamiento. El procedimiento consistió en estimar el aporte marginal de dicha variable a la predicción del modelo para cada observación y cada variable, considerando el efecto conjunto con las demás variables.

Los valores SHAP se calcularon sobre la salida cruda del modelo (raw output) con el fin de interpretar las contribuciones de cada variable en la decisión del algoritmo. Esta elección permite una comparación más directa de la influencia de los MoT y de los aspectos específicos. Este procedimiento se realizó de manera independiente para el nivel MoT → NPS y para aspectos → MoT, garantizando así que las comparaciones se mantuvieran dentro de cada nivel analítico y evitando interpretaciones cruzadas entre escalas distintas.

De forma complementaria, se implementó un análisis de importancia por permutación, utilizando la función *permutation_importance* de *scikit-learn*. Este procedimiento consiste en permutar aleatoriamente los valores de cada variable explicativa y evaluar el deterioro en el desempeño del modelo asociado a dicha permutación. La magnitud de esta variación se interpretó como una medida del grado en que el modelo depende de cada variable para realizar sus predicciones.

Al igual que con los valores SHAP, la importancia por permutación se calculó sobre el conjunto de prueba y se aplicó tanto a los modelos MoT → NPS como a los modelos aspectos → MoT, utilizando las métricas de evaluación definidas previamente para cada tipo de modelo. Este enfoque permitió contar con una medida adicional, basada directamente en el impacto sobre el desempeño predictivo que complementa la descomposición explicativa ofrecida por los valores SHAP.

La aplicación conjunta de estas dos técnicas en ambos niveles de análisis permitió reforzar la interpretabilidad de los modelos y asegurar una lectura más transparente de los resultados. De este modo, se estableció un marco analítico que no solo evalúa la capacidad predictiva de los modelos, sino que también facilita la identificación de los elementos de la experiencia del cliente que ejercen una mayor influencia, respetando la estructura jerárquica de la encuesta.

2.9 Árboles de decisión como herramienta interpretativa

Como complemento a los modelos de boosting se entrenaron árboles de decisión con el objetivo de obtener reglas explícitas que describan la relación entre las evaluaciones de la experiencia y el NPS. Este modelo se aplicó en tomando como objetivo final la clasificación de DEtractores y Promotores. Para esto, se usó como variable la clasificación de clientes resultante de la calificación del NPS (promotores, pasivos y detractores), y a partir de esta categorización, se entrenaron árboles de decisión. Queriendo mantener la interpratibilidad del

modelo y evitar estructuras muy complejas, se establecieron restricciones sobre la profundidad del árbol y el número mínimo de observaciones.

Los árboles de decisión se utilizaron principalmente como una herramienta de apoyo para la interpretación de resultados y la comunicación con áreas no técnicas de la empresa.

2.10 Análisis de causalidad: algoritmo PC

El algoritmo PC se implementó como una herramienta exploratoria de descubrimiento causal para identificar posibles relaciones direccionales entre los MoT y el NPS, bajo supuestos estándar de causalidad en datos observacionales. Los resultados se interpretan como hipótesis causales y no como inferencias causales definitivas.

3 Resultados

Inicialmente, se trabajan con 1'394.562 encuestas que, luego de la limpieza, la eliminación de nulos de nuestra variable objetivo y la división de los datos, resultaron siendo 1'292.655, una cantidad más que suficiente para hacer nuestro análisis. De estos datos, 503.493 encuestas fueron realizadas en el año 2025 y de estas, 89.713 representan las encuestas de compras realizadas en la omnicanalidad.

3.1 Análisis Descriptivo: Generales

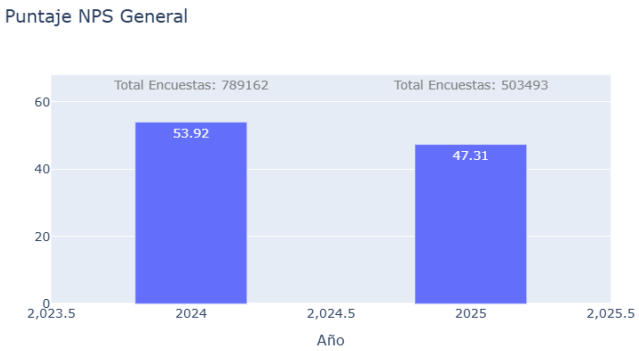

(a) *Puntaje NPS por año*

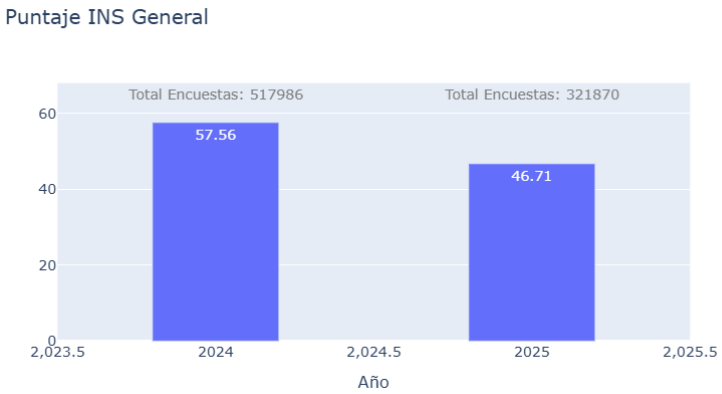

(b) *Puntaje INS por año*

Figura 2
Evolución anual del puntaje NPS e INS

Se observa una caída de casi 7 puntos en el puntaje NPS promedio para el año 2025 y de casi 11 puntos en el índice de satisfacción. Esto podría explicarse gracias a un cambio en

las herramientas usadas en la omnicanalidad para los procesos de pago y envío de productos, lo que podría haber generado malas experiencias a los clientes. También se observa una disminución en el número de encuestas registradas para el 2025.

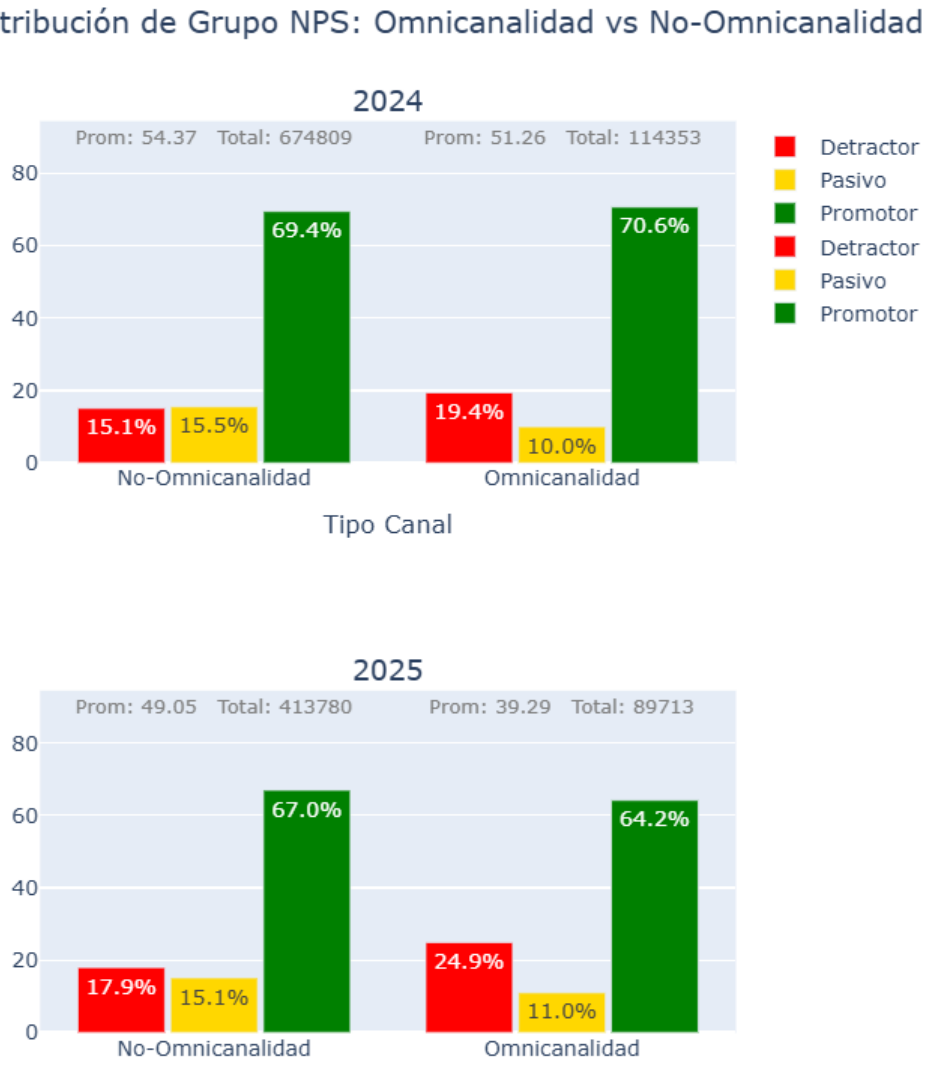

Figura 3

Distribución de la clasificación NPS en el 2024 y 2025 para la omnicanalidad y tienda física

En la omnicanalidad, se presenta la mayor caída de clientes Promotores, con una diferencia de 6,4 %, así como el aumento de Detractores en un 5,5 %, esto explica claramente la disminución del puntaje NPS.



Figura 4

Distribución de la calificación INS en el 2024 y 2025 para la omnicanalidad y tienda física

Respecto al INS, hay una disminución en el porcentaje de clientes que califican con un 5 y un leve aumento de calificaciones de 4. Esto nos indica que parte de los clientes que calificaban 5, empezaron a calificar con un 4 este indicador, pero también vemos que el porcentaje de 1 y 2 aumenta suustancialmente, lo que nos indica que hay algún factor que afectó gravemente la satisfacción y que posiblemente hizo que hubiera un salto de puntajes 4 o 5, a 1 o 2.

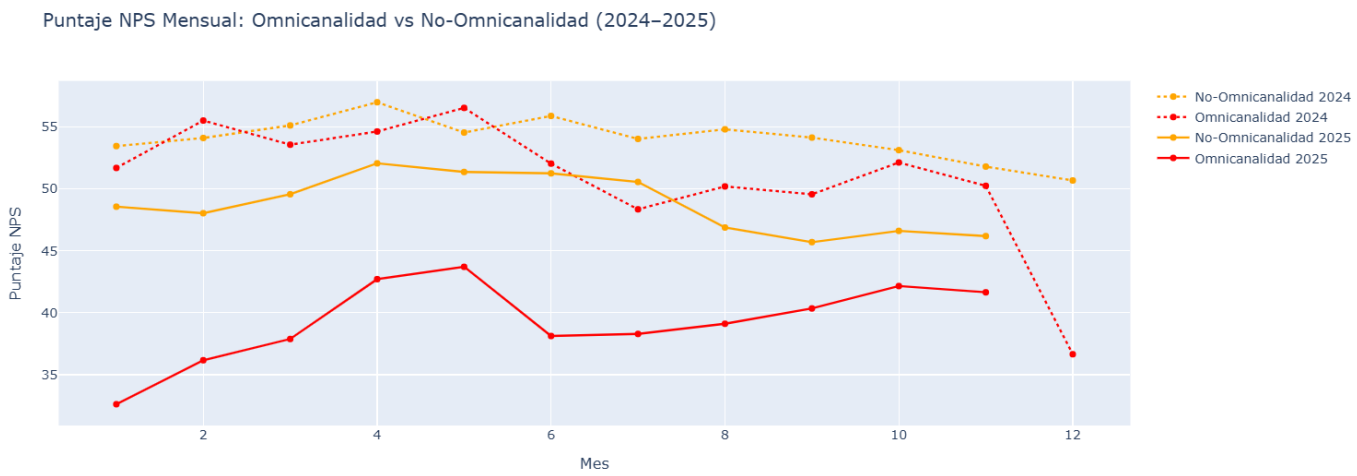

Figura 5

Evolución mensual del NPS para la omnicanalidad y tienda física en el 2024 y 2025

El puntaje promedio mensual del NPS en la Omnicanalidad muestra una caída significativa en el 2025, con una diferencia bastante notable en el puntaje, llegando a tener diferencias de hasta casi 20 puntos en comparación con los mismos meses del año 2024. El mes con mayor caída del NPS en la Omnicanalidad durante el 2025 fue junio.

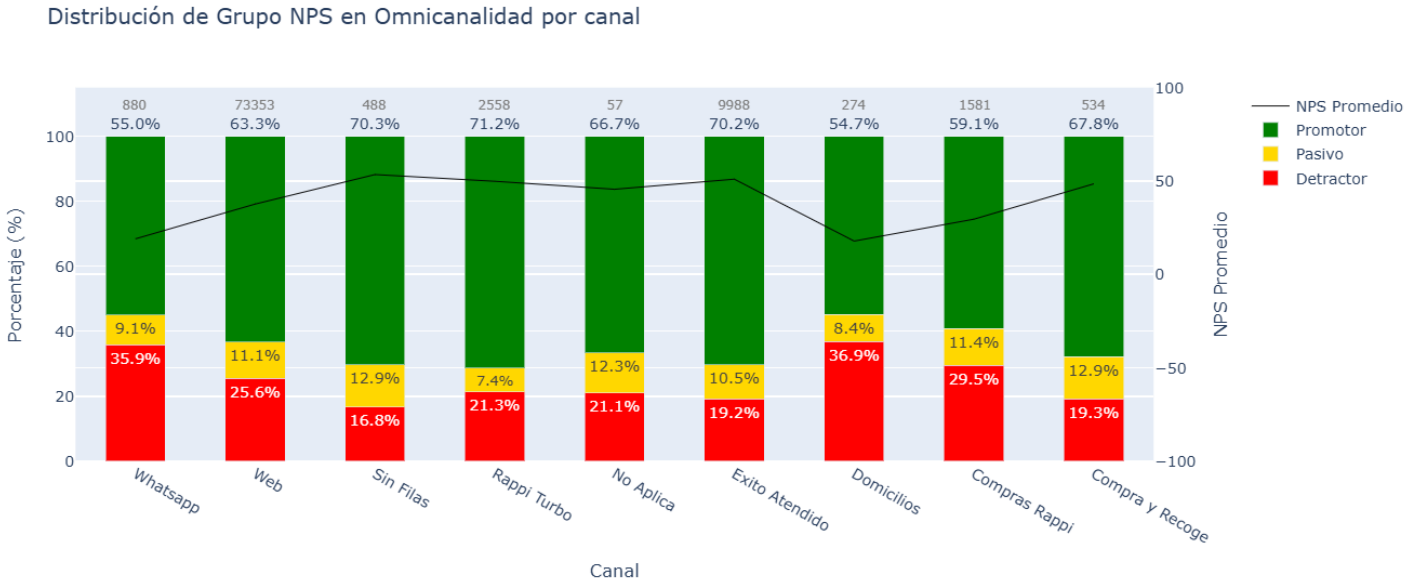

Figura 6

Distribución del grupo NPS y NPS promedio por canal de compra

La gráfica por canal nos puede dar una pista más especifica de qué es lo que está fallando en la compañía. Vemos que los canales de compra con el puntaje más bajo para el

2025 fueron 'Domicilios'y 'Whatsapp'. Esto ya nos da un indicio de las áreas que necesitan un cuidado especial.

3.1.1 Distribuciones de calificación por MoT

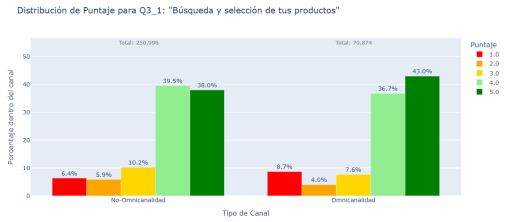

(a) $Q3_1$

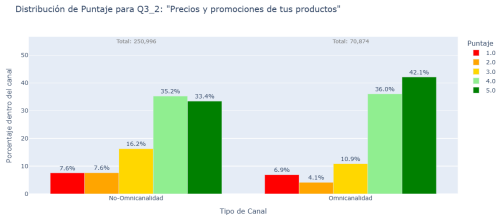

(b) $Q3_2$

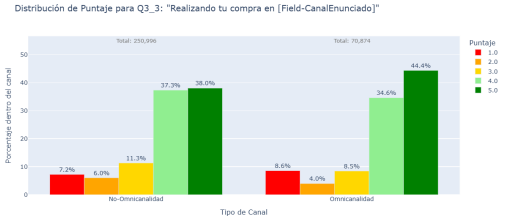

(c) $Q3_3$

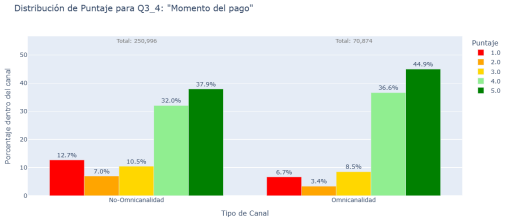

(d) $Q3_4$

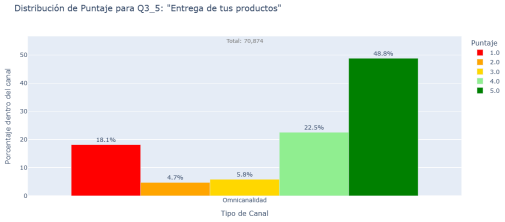

(e) $Q3_5$

Figura 7

Distribución de la calificación para las preguntas del bloque de MoT

En las distribuciones del puntaje de los MoT podemos notar que aquel momento con mayor número de calificaciones 5 es Éntrega de productos', pero además, es el que menos porcentaje de 4 muestra y el que más 1 tiene. Esto nos indica que los clientes suelen ser mucho más contundentes a la hora de calificar este momento, evitando calificaciones neutras y yendose a los extremos. Las opiniones más neutras suelen asignarlas al momento 'Precios y promociones de los productos'.

También se gráficaron estas distribuciones para cada aspecto especifico del MoT encontrando un número de encuestas muy bajo para las siguientes preguntas:

- $Q1_3$
- $Q1_2$
- $Q5_6$
- $Q7_2$
- $Q7_5$
- $Q7_10$
- $Q8_2$

3.2 Análisis Multivariado

3.2.1 Tablas de contingencia

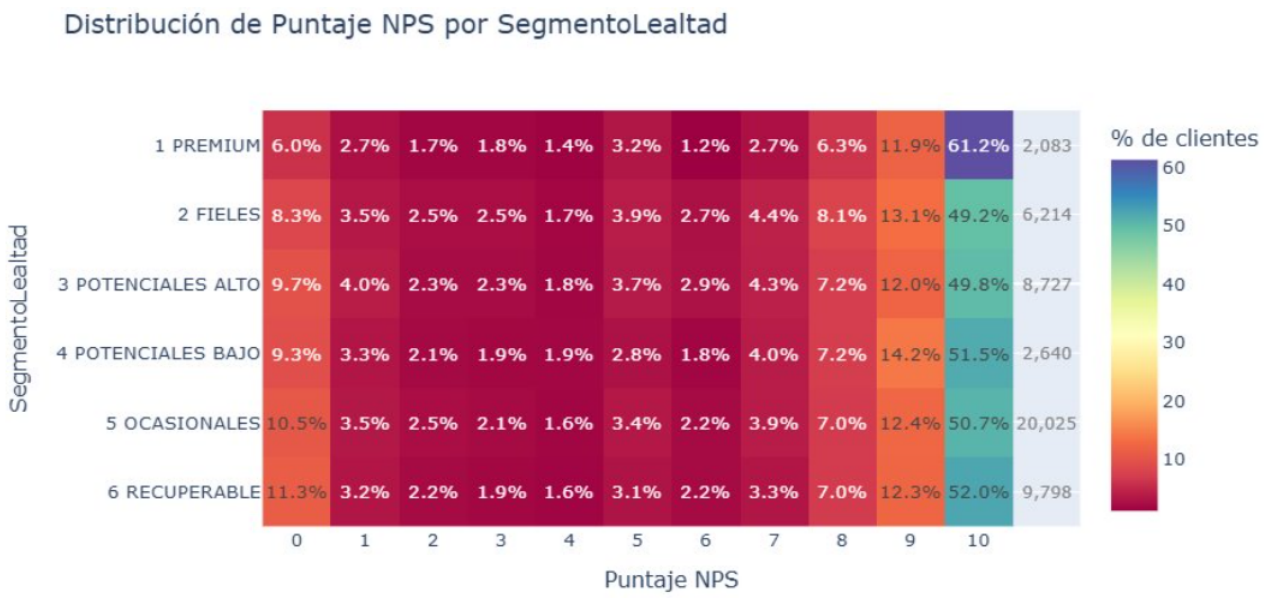

Figura 8

Tabla de contingencia para el segmento de clientes Éxito y NPS

Para los almacenes Éxito, el cliente Premium es el que contiene un mayor porcentaje de calificación 10 y el cliente Recuperable, calificación 0. Mientras que aquel segmento que tiene un menor porcentaje de calificaciones 10 es Fieles y de calificación 0, los Premium. Con esto podemos ver que los premium suelen dar calificaciones más positivas en comparación con los demás segmentos.

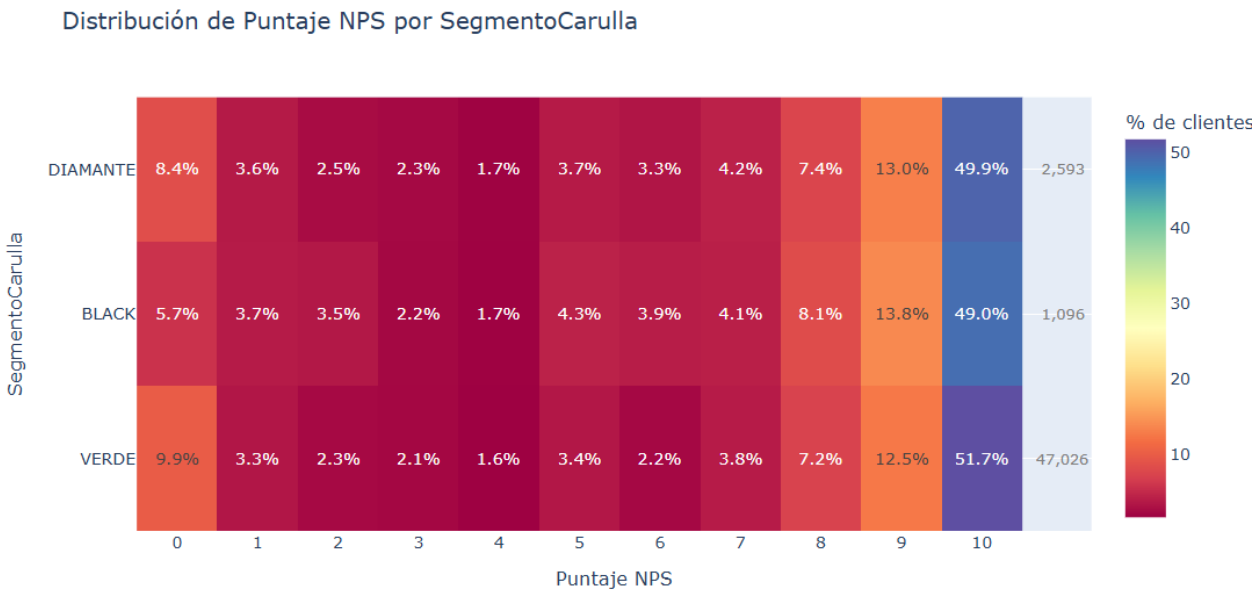

Figura 9

Tabla de contingencia para el segmento de cliente Carulla y NPS

Para Carulla, vemos que el cliente Verde, que es aquella categoría en la que inicia un cliente que se está fidelizando, es el que contiene un mayor porcentaje de calificación 10 y al mismo tiempo de calificación 0, es decir, suelen ser más extremos en sus calificaciones en comparación de, por ejemplo, un cliente Black, que es aquel que está en el segundo nivel. Finalmente, respecto a los clientes Diamante, que son aquellos de más alto valor, se encuentra en una posición media al momento de dar una calificación.

Ahora, analizando los pares de respuestas de cada MoT con el NPS, las gráficas más significativas fueron las siguientes.

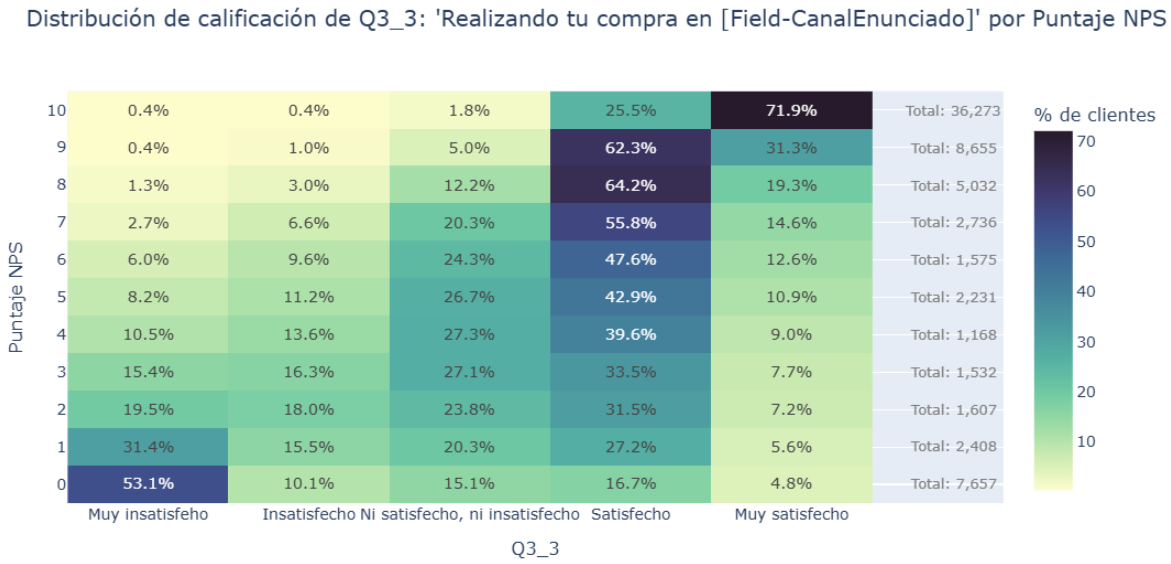

Figura 10

Tabla de contingencia para Q3_3 y NPS

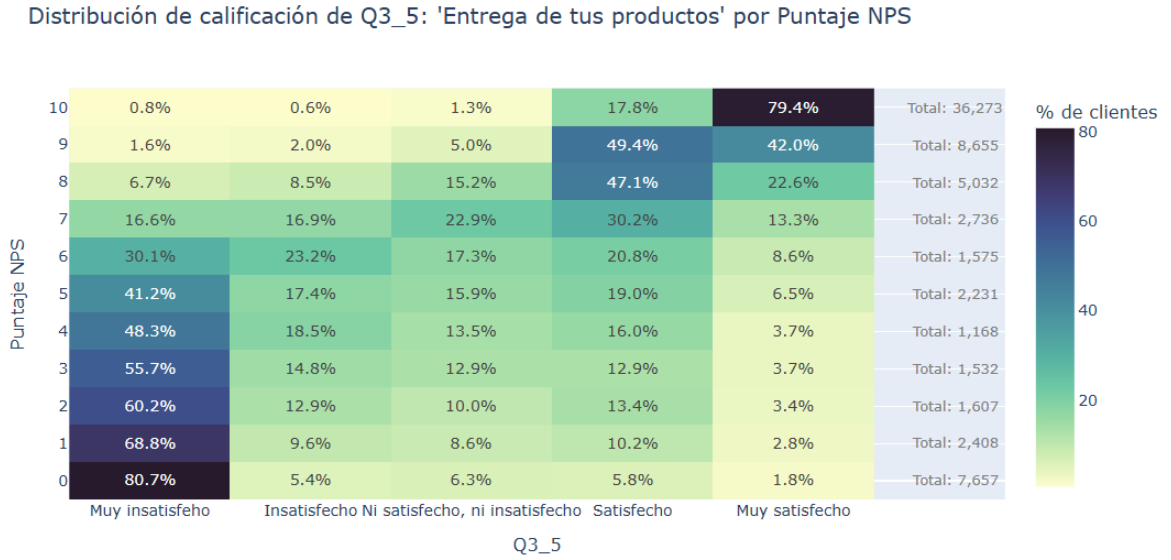

Figura 11

Tabla de contingencia para Q3_5 y NPS

En estas 2 gáficas vemos un contraste. Para la $Q3_5$, vemos que la mayoría de clientes que califican al NPS con valores bajos, también suelen calificar mal este momento con 'Muy insatisfecho', y las calificaciones neutras a las preguntas son más frecuentes en las calificaciones altas del NPS. Mientras que si observamos la pregunta $Q3_3$, pasa lo contrario. Una gran

parte de clientes, pueden dar calificaciones bajas al NPS pero al mismo tiempo, calificar de forma neutra o positiva este momento.

3.2.2 Análisis de correspondencia múltiple

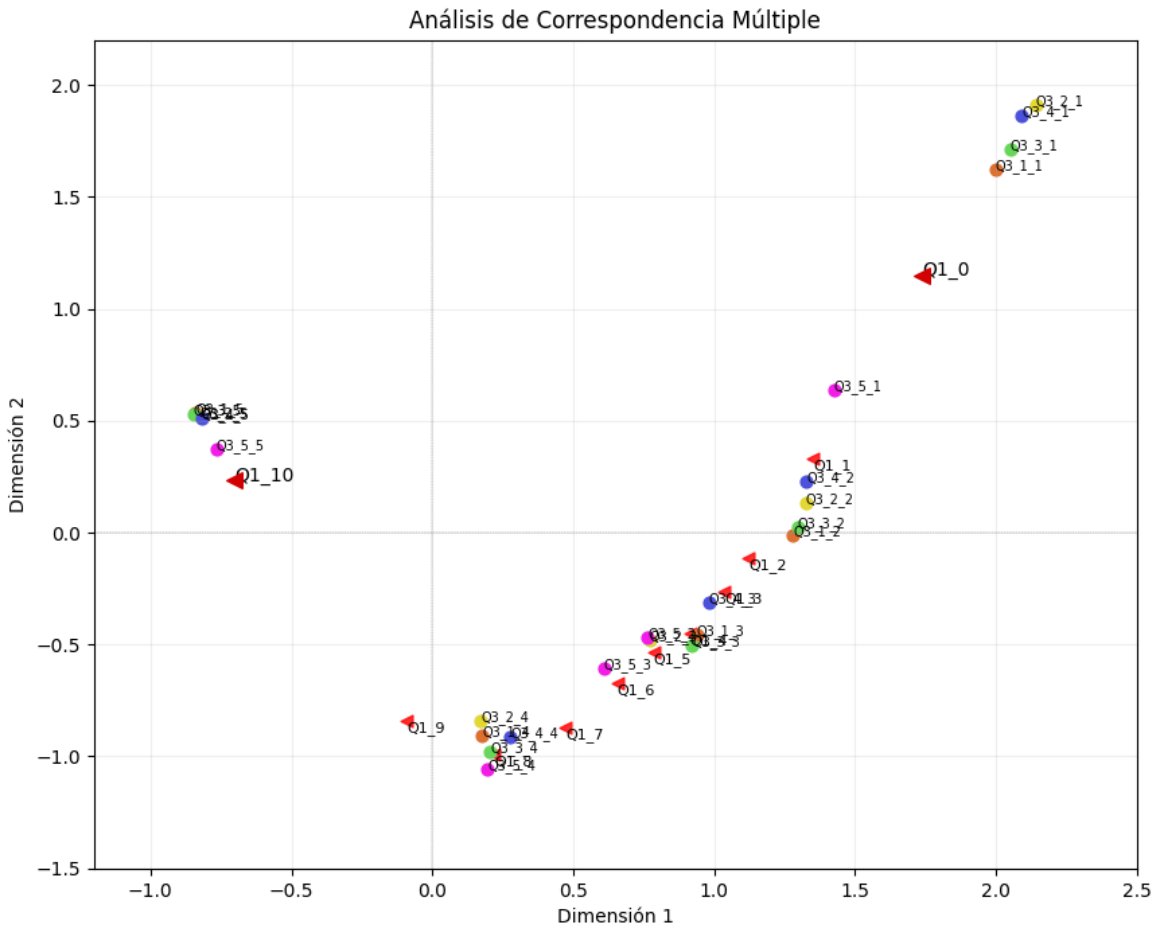

Figura 12

Análisis de correspondencia múltiple entre NPS y MoT

En la primera dimensión (eje x) se observa que las categorías bajas del NPS (por ejemplo, NPS 0–3) se agrupan espacialmente en la región derecha del plano y se encuentran próximas a calificaciones bajas de los MoT, lo que nos indica una fuerte asociación de experinecias deficientes en momentos clave del recorrido del cliente y una baja disposición a recomendar. Esta proximidad en el espacio factorial sugiere que las evaluaciones negativas de los MoT no son independientes del NPS, sino que contribuyen de manera sistemática a su deterioro.

Por otro lado, las categorías altas del NPS (NPS 9–10) se concentran en el extremo izquierdo del plano y se encuentran cercanas a calificaciones altas de los MoT, evidenciando así, una asociación fuerte entre una experiencia positiva en los MoT y una alta probabilidad

de recomendación.

Aunque la segunda dimensión explica una menor proporción de la inercia total, esta introduce una diferenciación adicional entre MoT con evaluaciones similares en promedio, pero con patrones de respuesta distintos. Esto nos sugiere que no todos los MoT contribuyen de la misma manera al NPS incluso cuando reciben calificaciones comparables, lo que apunta a la existencia de heterogeneidad en las resouestas. Esto nos indica que mejorar de forma homogénea todos los MoT no necesariamente maximiza el impacto sobre el NPS. En cambio, los MoT que aparecen más próximos a las categorías extremas del NPS en el espacio factorial se pueden considerar palancas para la mejora del servicio. Este insight justifica el uso posterior de modelos predictivos e interpretables para cuantificar la contribución específica de cada MoT y de sus atributos subyacentes, así como la exploración de relaciones causales que permitan distinguir correlación de influencia estructural.

3.3 PCA

El balanceo de los bloques se realizó con aquellas preguntas que resultaron luego de eliminar las que tenían pocas respuestas. Con este filtro, se logró tener 10.773 respuestas en cada bloque, sin tener ningún valor faltante.

Se eligió el primer componente resultante del PCA para cada bloque pues este ya representaba más del 75 % de la varianza explicada. Como resultado, la contribución de cada aspecto en la construcción de su respectivo MoT es presentado a continuación.

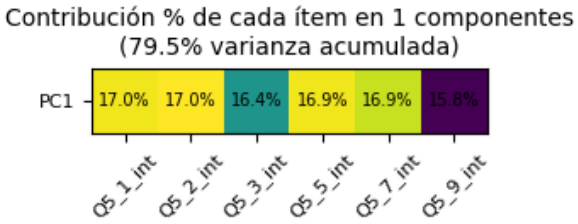

(a) *PCA 5*

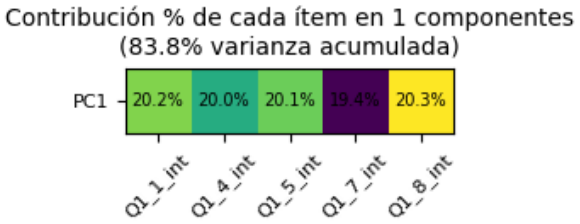

(b) *PCA 1*

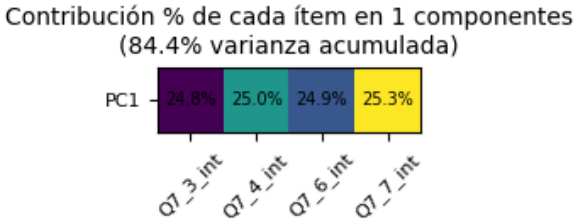

(c) *PCA 7*

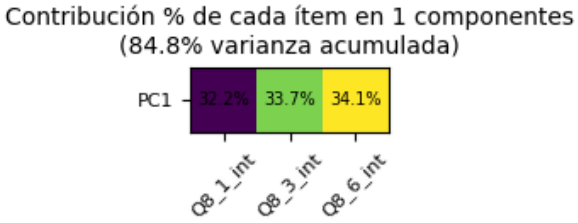

(d) *PCA 8*

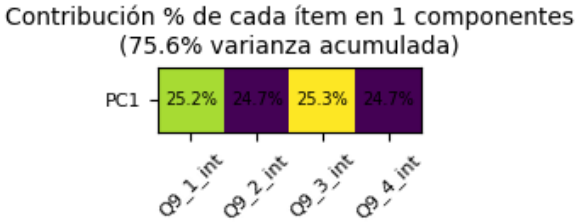

(e) *PCA 9*

Figura 13

Contribución de los aspectos a la construcción del PCA de sus respectivos MoT

Como vemos en la figura 13, cada aspecto especifico aportó en una proporción similar a la de los demás aspectos, lo que hace que la construcción de la nueva variable latente sea fuerte y guarde información importante.

Ahora, los PCA asociados a cada MoT explican una proporción alta de la varianza interna de los aspectos que los componen. Para todos los casos, la varianza explicada por el primer componente se sitúa alrededor del 75 %–85 %, es decir, el PCA está capturando una dimensión coherente dentro de cada bloque de aspectos. Es decir, los aspectos sí comparten una estructura latente común.

Sin embargo, cuando se compara esta vairbale resultante con la calificación dada a cada MoT de forma directa (figura 14), vemos que las correlaciones de Spearman entre ellas

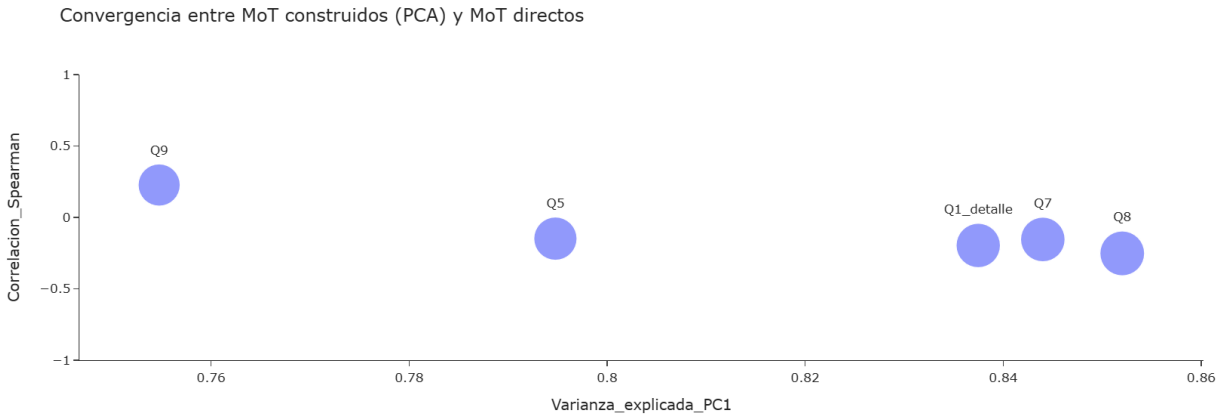

Figura 14
Convergencia del MoT y el PCA.

son bajas, y no sólo esto, sino que en la mayoría son negativas. Solo el MoT Q9-Entrega de productos, tiene una correlación positiva pero moderada.

Aunque los aspectos de cada MoT se organizan de forma interna de una manera consistente, el PCA no refleja la calificación global del MoT, por lo que la calificación del MoT puede incluir aspectos adicionales que no son evaluados dentro de los aspectos. Esto nos indica que ambos niveles de calificación son importantes dentro de la encuesta pues al descartar los MoT, estaríamos perdiendo información complementaria.

3.4 Desempeño de los modelos HGB, importancia de las variables e interpretabilidad

3.4.1 Nivel MoT → NPS

Como vemos en la figura 16, el modelo prioriza correctamente la clase mayoritaria (Promotores). Con 10,803 aciertos, el modelo es muy efectivo para no perder promotores (alta sensibilidad para la clase mayoritaria). Esto es útil para la toma de decisiones de fidelización y marketing positivo.

La clase Pasivo es la más difícil de modelar, incluso considerando el desbalance. Solo hay 286 aciertos vs 1,656 errores (535 como Detractores + 1,121 como Promotores). Esto sugiere que los Pasivos tienen un perfil de experiencia similar a Promotores o Detractores,

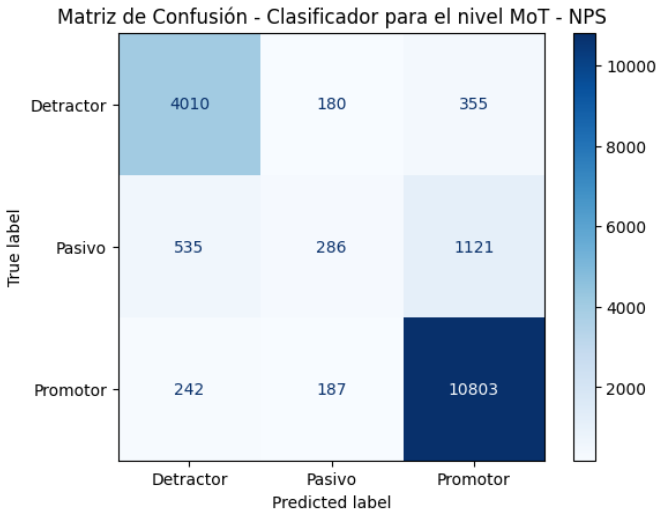

Figura 15

Matriz de confusión para el modelo clasificador

dependiendo del contexto. Esto nos puede indicar que los clientes Pasivos son volátiles y su clasificación errónea puede llevar a estrategias de retención inefectivas.

Por otro lado, la clase Detractor tiene mejor precisión relativa que Pasivo: 4,010 aciertos vs 535 errores (clasificados como Pasivos). Esto indica que el modelo sí puede identificar señales claras de insatisfacción, aunque con cierto solapamiento con Pasivos.

El modelo tiende a empujar Pasivos hacia Promotores: De los errores en Pasivos, 1,121 fueron clasificados como Promotores vs solo 535 como Detractores, lo cual puede ser peligroso porque se podrían dejar de atender clientes en riesgo (Pasivos) al considerarlos satisfechos.

En la figura 16 vemos, usando el método de la importancia por permutación, que la Entrega de productos es claramente la variable más determinante para explicar el NPS. Esto confirma que desde una perspectiva predictiva global, la experiencia postcompra es el factor que más degrada o mejora la capacidad del modelo para predecir correctamente la lealtad del cliente. Con un peso significativamente menor, le siguen en importancia, la Búsqueda/Selección de productos, la Experiencia del canal, la Comparación de Precios/Promociones y finalmente el Momento del pago.

Al analizar los valores SHAP para clientes Promotores y Detractores por separado, se notan dinámicas distintas en la influencia de cada variable. Para los Promotores, la gráfica de SHAP muestra una distribución compacta de valores alrededor del cero para casi todas

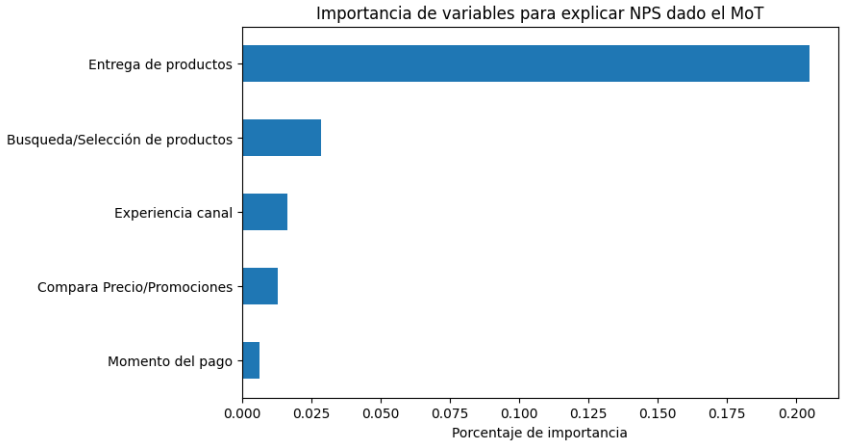

Figura 16

Importancia por permutación

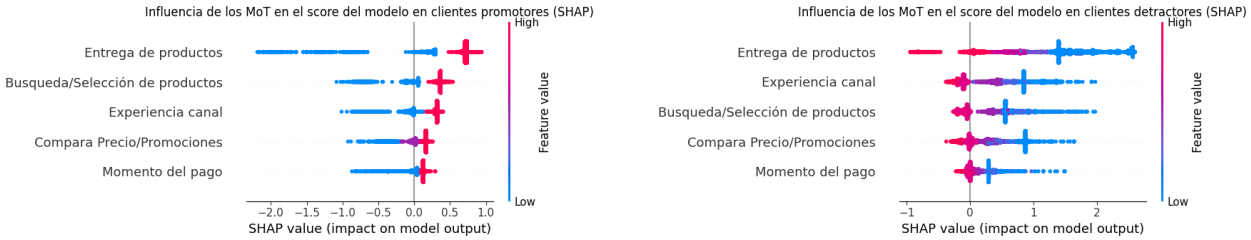

(a) *Valores Shap (Promotores)* **(b)** *Valores Shap (Detractores)*

Figura 17

Comparación de métricas de importancia de variables.

las variables, excepto para Entrega de productos. Esto nos indica que entre los clientes satisfechos, una calificación positiva en la entrega tiene un impacto positivo moderado en el score del modelo, pero en general, los promotores no se definen por puntuaciones extremadamente altas en ningún MoT específico.

Por el contrario, la gráfica de SHAP para los Detractores es mucho más clara y potente. Aquí podemos ver que la variable Entrega de productos la influencia con valores SHAP altamente negativos y una dispersión amplia. Esto significa que una mala calificación en la entrega está fuertemente asociada con que un cliente sea clasificado como detractor por lo que este actua como el principal impulsor de la insatisfacción. Además, la Experiencia del canal también muestra una influencia negativa relevante para este grupo, en comparación a la de los Detractores, sugiriendo que los problemas en la interacción con el canal de compra (digital o físico) son un factor significativo de la insatisfacción.

3.4.2 Nivel Aspectos → NPS

Búsqueda de selección de productos

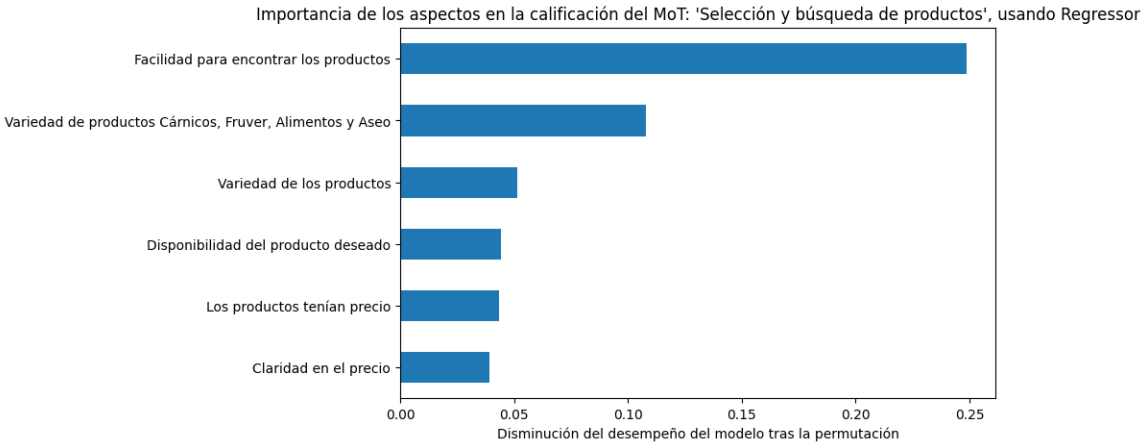

Figura 18

Importancia por permutación del bloque Búsqueda y Selección de pProductos

En este bloque de preguntas, se identifica a la Facilidad para encontrar los productos como el aspecto más crítico, lo que sugiere que la usabilidad y navegación en el proceso de búsqueda es el factor que más afecta la capacidad predictiva del modelo. Esto indica que si el cliente no puede localizar fácilmente lo que necesita, su evaluación del MoT se verá significativamente perjudicada.

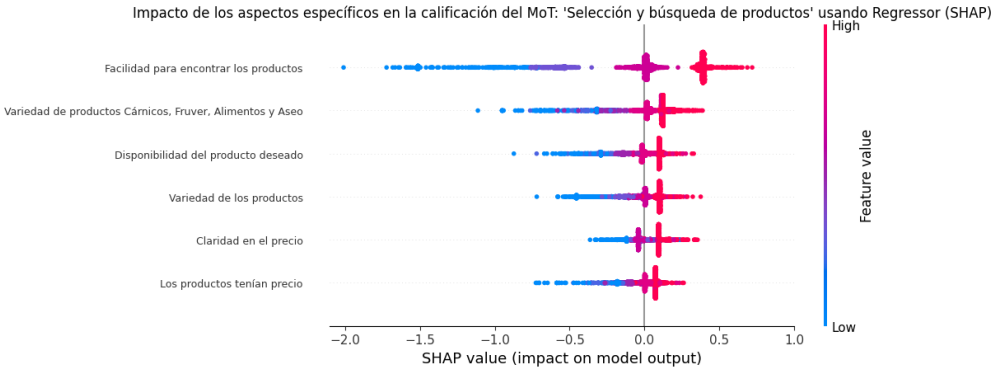

Figura 19

Impacto en el desempeño del modelo para la Búsqueda y Selección de Productos (SHAP)

Aquí, la Variedad de productos (Cárnicos, Fruver, Alimentos y Aseo) es la variable con mayor impacto, mostrando que una oferta diversa y completa en estas categorías básicas

impulsa calificaciones favorables. Pero también se observa que la Disponibilidad del producto deseado tiene una influencia notable, pero con gran dispersión hacia los valores negativos. Esto es un riesgo operativo pues la falta de stock de productos específicos puede generar una fuerte insatisfacción, incluso si la variedad general es buena.

Otros aspectos como la Claridad en el precio y que Los productos tuvieran precio muestran influencias más moderadas y centradas cerca del cero. Esto sugiere que son elementos esperados o hygiene factors: su presencia no necesariamente mejora la evaluación, pero su ausencia o deficiencia podría causar frustración.

Precios y promociones

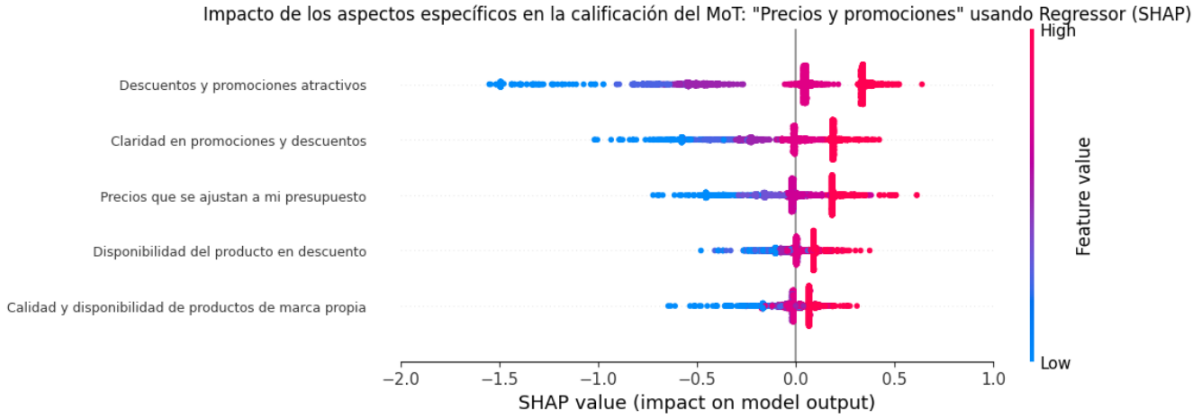

Figura 20

Impacto en el desempeño del modelo para los Precios y Promociones (SHAP)

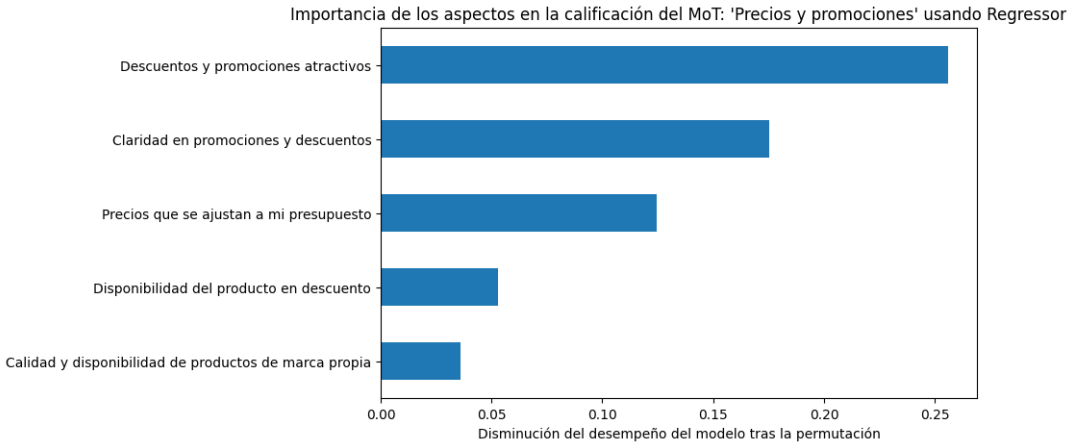

Figura 21

Importancia de permutación del bloque de Precios y Promociones (SHAP)

En el análisis para el MoT Precios y Promociones, figura 21, muestra que Descuentos y promociones atractivas son el aspecto más determinante, tanto en importancia por permutación como en impacto SHAP. Esto indica que la percepción de valor ofrecido es importante para la evaluación de este momento.

La claridad en promociones y descuentos también tiene un peso significativo que nos sugiere que una comunicación confusa puede dañar la confianza incluso si las ofertas son buenas. Por otro lado, aspectos como el ajuste al presupuesto, la disponibilidad de productos en descuento y la calidad de marca propia muestran una influencia más moderada.

Aspectos del sitio

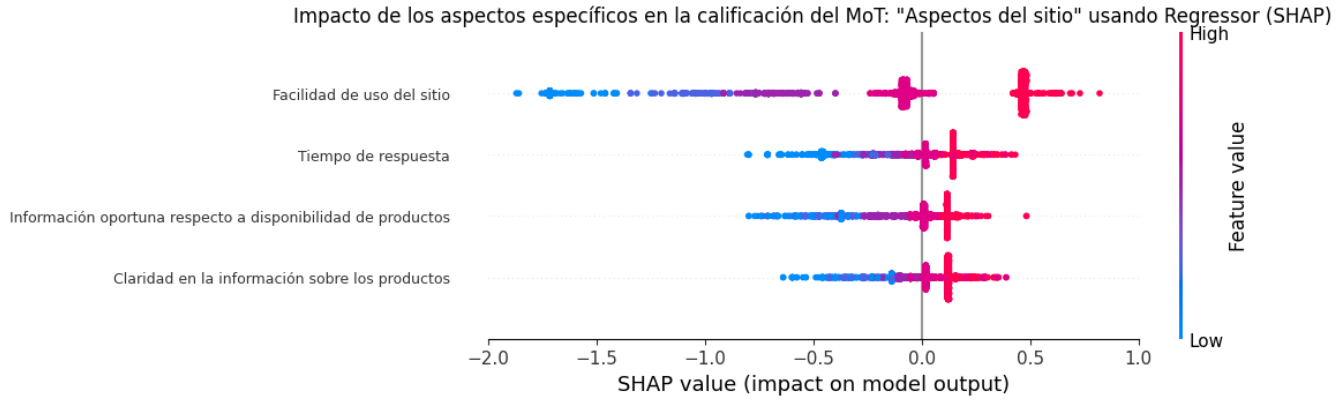

Figura 22

Impacto en el desempeño del modelo para el bloque Aspecto del Sitio (SHAP)

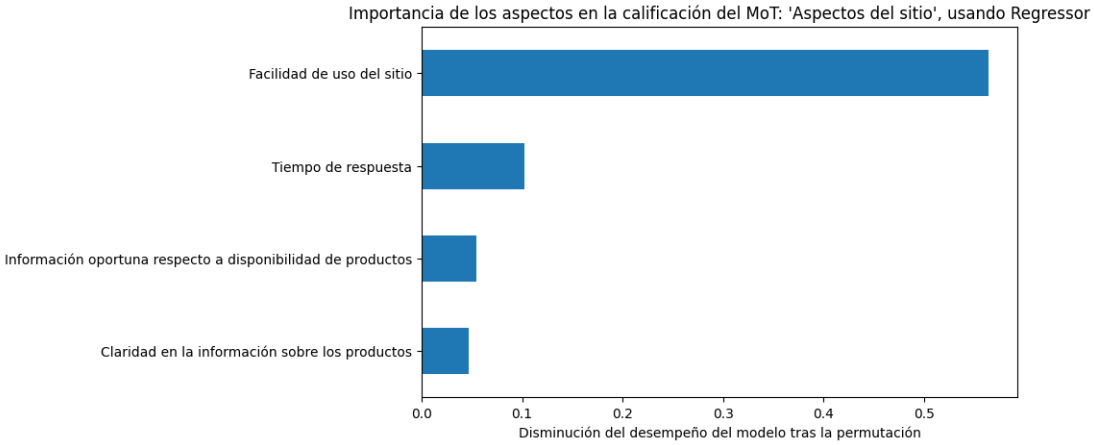

Figura 23

Importancia de permutación del bloque de Aspectos del Sitio (SHAP)

La gráfica del bloque Aspectos del Sitio muestra que lo más importante para el cliente es la facilidad de uso. Si la plataforma es confusa o difícil de navegar, la calificación cae drásticamente. En segundo lugar está la velocidad: un sitio lento frustra de inmediato.

La información sobre disponibilidad y claridad de los productos, aunque necesaria, tiene un impacto menor. Son como la base: si fallan molestan, pero si funcionan bien no sorprenden. Finalmente, para mejorar la experiencia, hay que enfocarse primero en hacer el sitio fácil y rápido.

Pago de los productos

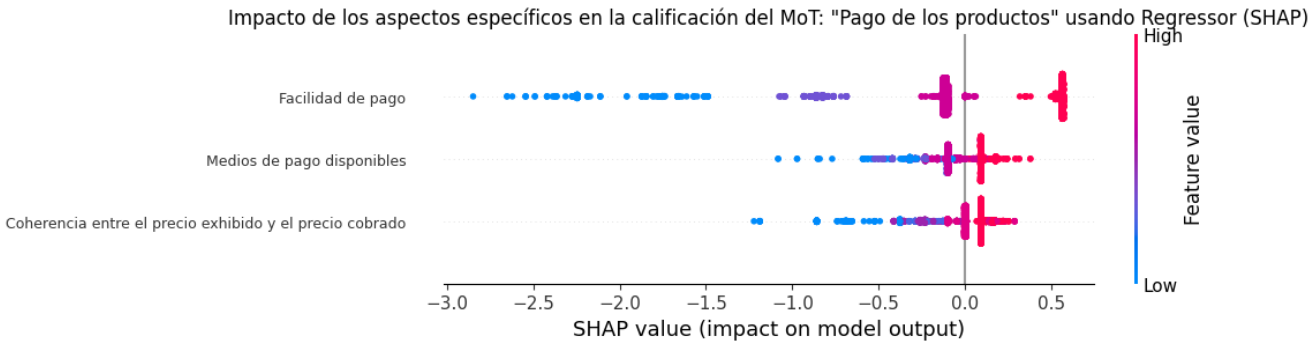

Figura 24

Impacto en el desempeño del modelo para el bloque Pago de los Productos (SHAP)

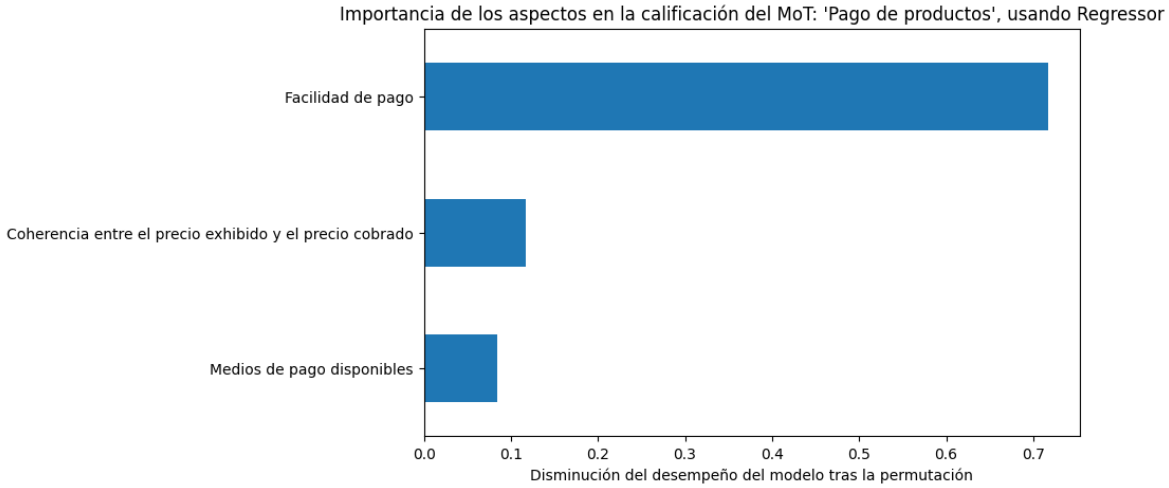

Figura 25

Importancia de permutación del bloque de Pago de los Productos (SHAP)

La gráfica del bloque Pago de los productos nos muestra que la facilidad de pago es el aspecto más importante, lo que indica que cualquier complicación en este paso final tiene un

efecto devastador en la percepción global del momento. Los valores SHAP confirman esto, mostrando que cuando la facilidad de pago es baja, el impacto negativo en la evaluación es extremo y directo.

El segundo factor en importancia es la coherencia entre el precio exhibido y el cobrado. Este no es un atributo de valor agregado, sino un requisito fundamental de confianza. Un error en el precio cobrado es percibido como una falta de transparencia grave y erosiona inmediatamente la credibilidad de la marca. Los medios de pago disponibles muestran una influencia menor. Esto sugiere que, mientras existan opciones básicas y comunes, la variedad extrema no es un impulsor principal de satisfacción en este contexto.

Entrega de productos

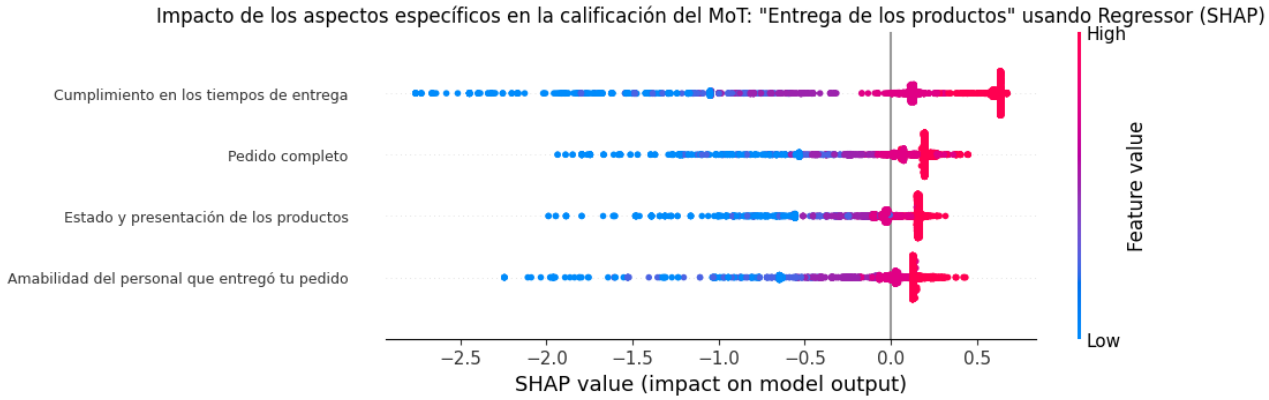

Figura 26

Impacto en el desempeño del modelo para el bloque Entrega de producto (SHAP)

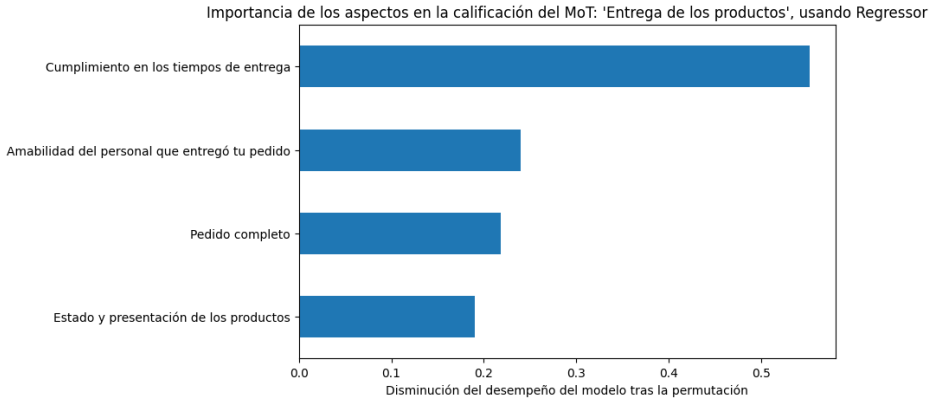

Figura 27

Importancia de permutación del bloque de Entrega de producto (SHAP)

El análisis del bloque Entrega de productos confirma por qué este momento es el más determinante para el NPS. Aquí, el cumplimiento en los tiempos de entrega es el aspecto más importante. Su importancia por permutación es la más alta, por lo que es la variable que más información le da al modelo para predecir la evaluación de este MoT. Los valores SHAP refuerzan este hallazgo fuertemente: cuando los tiempos no se cumplen, el impacto negativo es profundo y concentrado teniendo valores SHAP muy bajos. En el comercio actual la promesa de entrega es muy importante; romperla es la forma más rápida de crear un detractor.

La amabilidad del personal que entrega el pedido emerge como el segundo factor más importante. Esto revela que incluso si el pedido llega a tiempo, una interacción fría, apresurada o descortés puede dañar la experiencia.

3.4.3 Desempeño del modelo regresor

Dimensión (MoT)	**Set**	**MAE**	**RMSE**	R^2
Búsqueda y selección	Train	0.3805	0.6245	0.7094
	Test	0.4220	0.7029	0.6318
Precios y Promociones	Train	0.3507	0.5717	0.7306
	Test	0.3530	0.5863	0.7166
Aspectos del sitio	Train	0.3819	0.6381	0.7055
	Test	0.4167	0.6866	0.6592
Pago de productos	Train	0.3586	0.5883	0.7087
	Test	0.3603	0.5990	0.6987
Entrega de productos	Train	0.3773	0.6403	0.8213
	Test	0.4121	0.7015	0.7856

Tabla 2

Desempeño del modelo regresor

La Tabla 2 muestra un desempeño sólido de la predicción de los modelos de regresión para cada bloque de aspectos especificos. En todos los casos, los valores de R^2 en el conjunto de prueba son altos (entre 0.63 y 0.79), confirmando que los aspectos específicos logran explicar una proporción significativa de la variación en la calificación global de cada MoT. El modelo para Éntrega de productos'destaca con el R^2 más alto (0.7856), reforzando su papel como el momento más estructurado y predecible, donde los aspectos medidos capturan eficazmente la experiencia. Las pequeñas diferencias entre las métricas de entrenamiento y prueba indican que los modelos generalizan bien, sin sobreajuste significativo.

3.5 Árboles de decisión

MoT → NPS

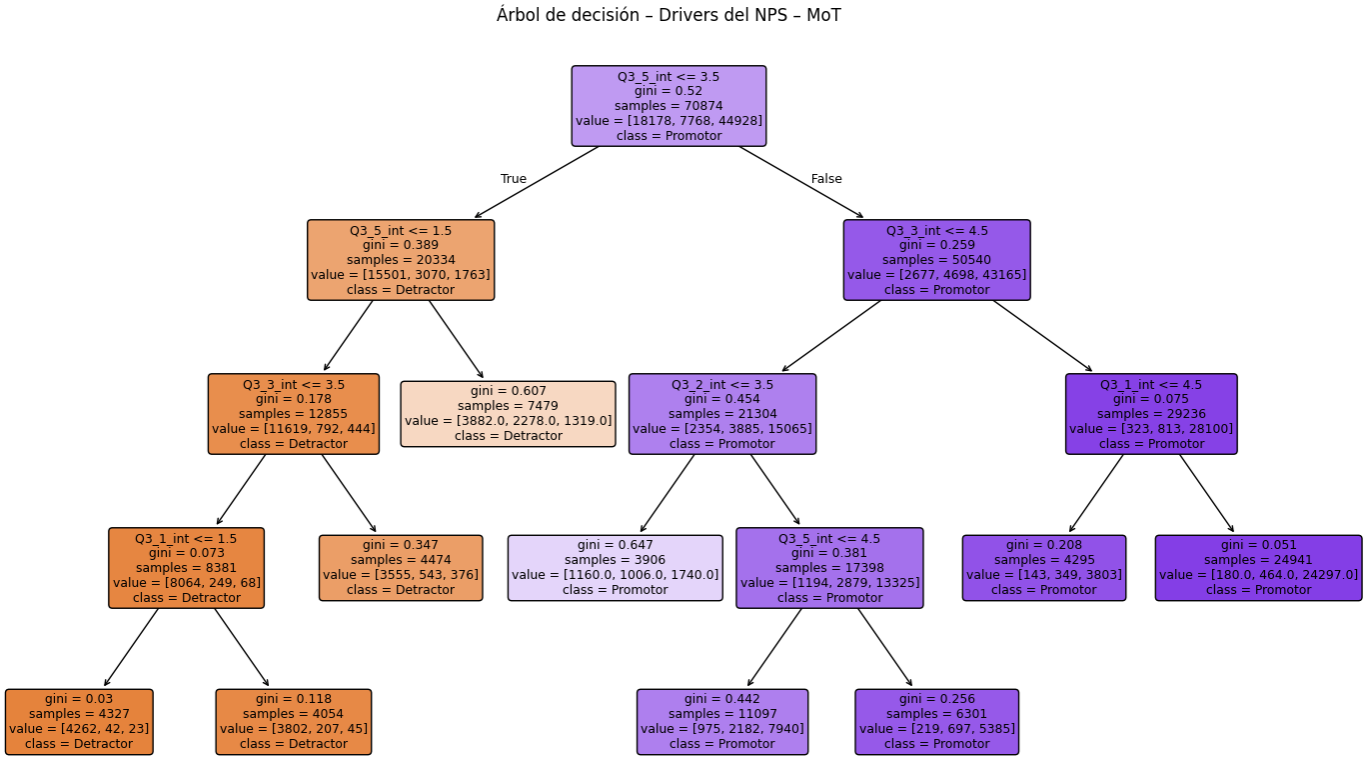

Figura 28
Árbol de decisión para los MoT.

La calificación del MoT Entrega de productos ($Q3_5_int$) es la variable raíz más poderosa. Si se califica menor a 3.5, el cliente tiende a ser Detractor; si la calificación es > 3.5, tiende a ser Promotor. Esto confirma que la entrega es el principal divisor de experiencias positivas y negativas.

Aspecto→ MoT

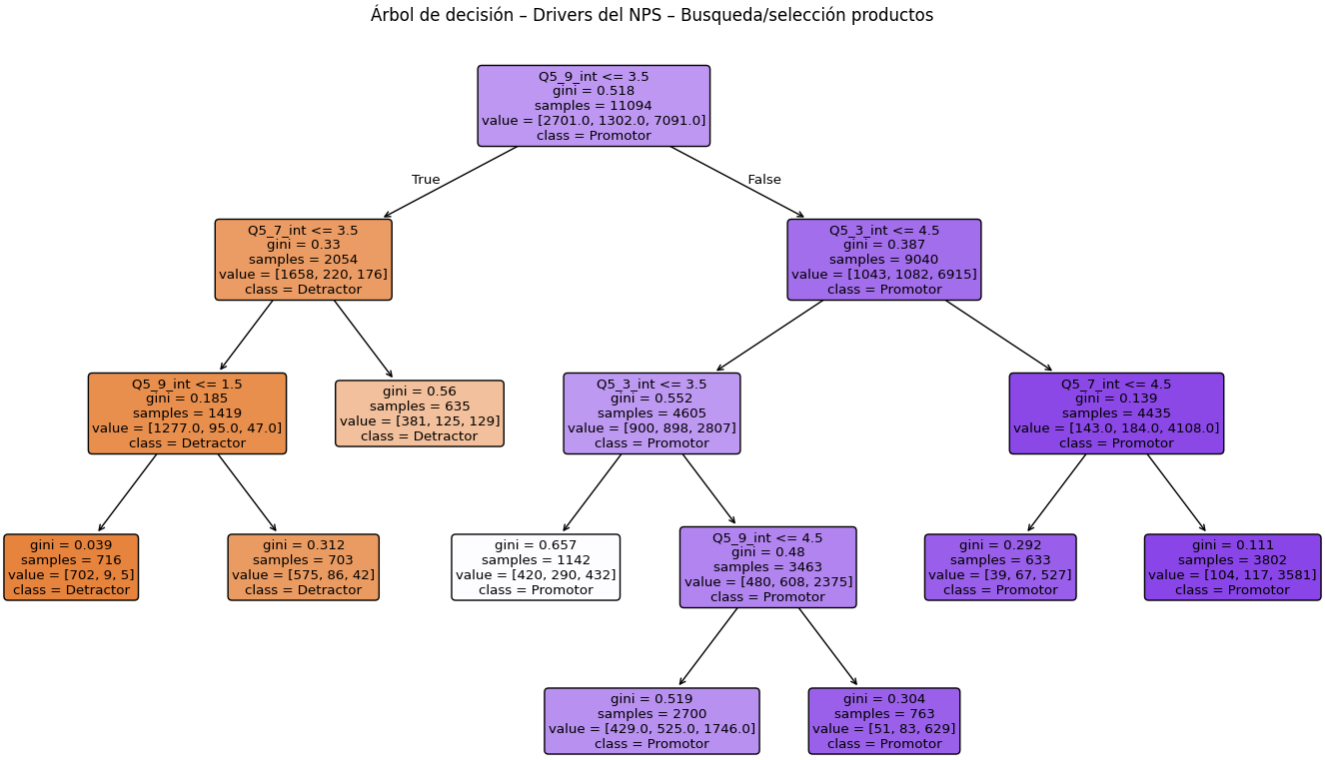

Figura 29

Árbol de decisión para el bloque de Búsqueda y selección de productos.

Aquí, la variable que inicia la división es la facilidad para encontrar productos ($Q5_9_int$). Una calificación 3.5 predice fuertemente un cliente Detractor. Solo cuando esta evaluación es alta, (> 3.5) el árbol considera otros aspectos como la variedad, para identificar Promotores.

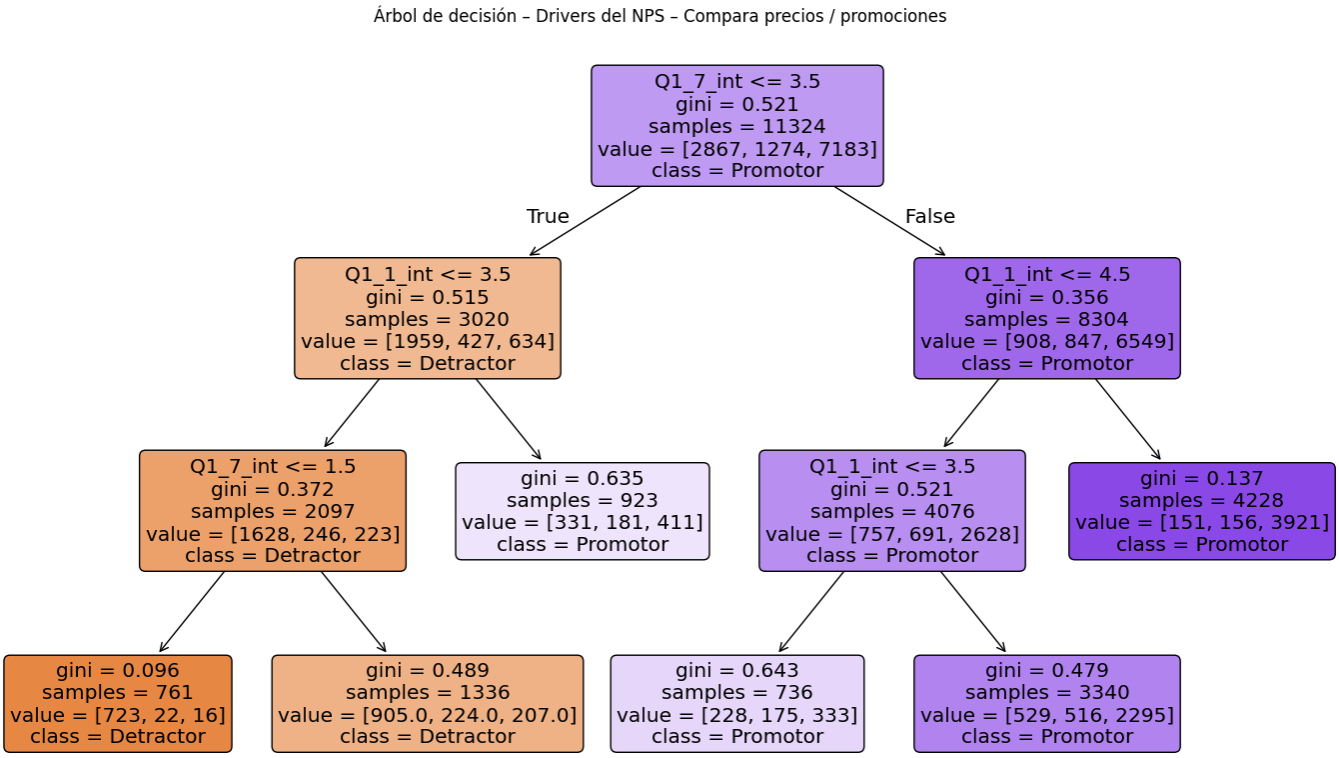

Figura 30

Árbol de decisión para el bloque de Precios y promociones.

La percepción de descuentos atractivos ($Q1_7_int$) es la primera regla. Una evaluación 3,5 agrupa a la mayoría de Detractores. En la rama positiva (3,5), la claridad de las promociones ($Q1_1_int$) toma el relevo para refinar la clasificación de Promotores.

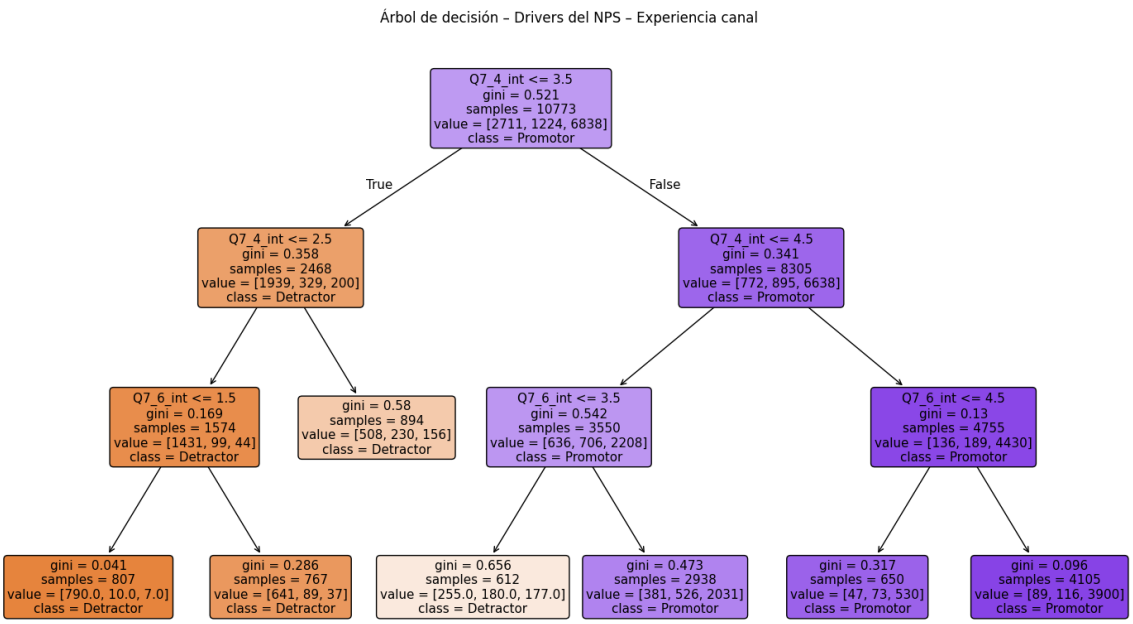

Figura 31

Árbol de decisión para el bloque de Aspectos del sitio.

El nodo principal es la calificación general del canal ($Q7_4_int$). Una nota 3.5 conduce mayoritariamente a Detractores. Para quienes califican mejor (> 3.5), la velocidad del sitio ($Q7_6_int$) se convierte en el siguiente filtro crítico para separar Promotores de los demás.

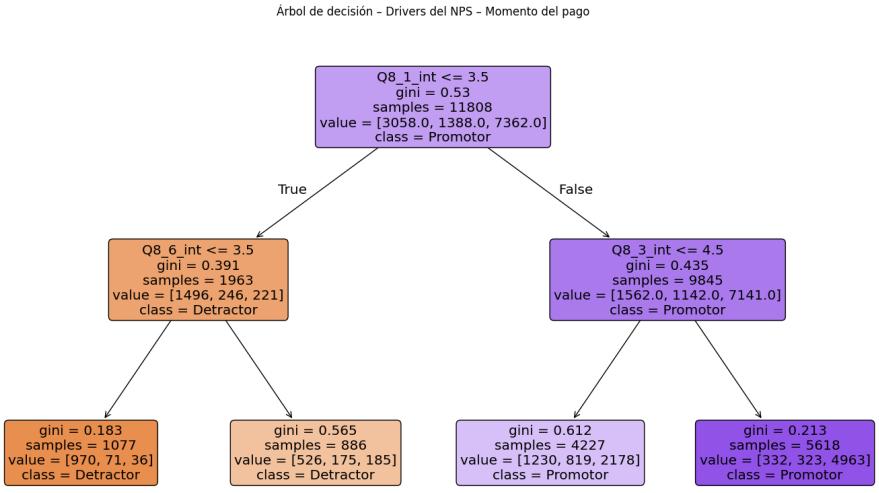

Figura 32

Árbol de decisión para el bloque de Proceso de pago.

La facilidad de pago ($Q8_1_int$) es la variable decisiva. Una calificación ≤ 3.5 apunta a Detractor. En la rama donde la facilidad es alta (> 3.5), la seguridad en el pago ($Q8_6_int$) y la claridad del cobro ($Q8_3_int$) actúan como filtros secundarios para identificar Promotores puros.

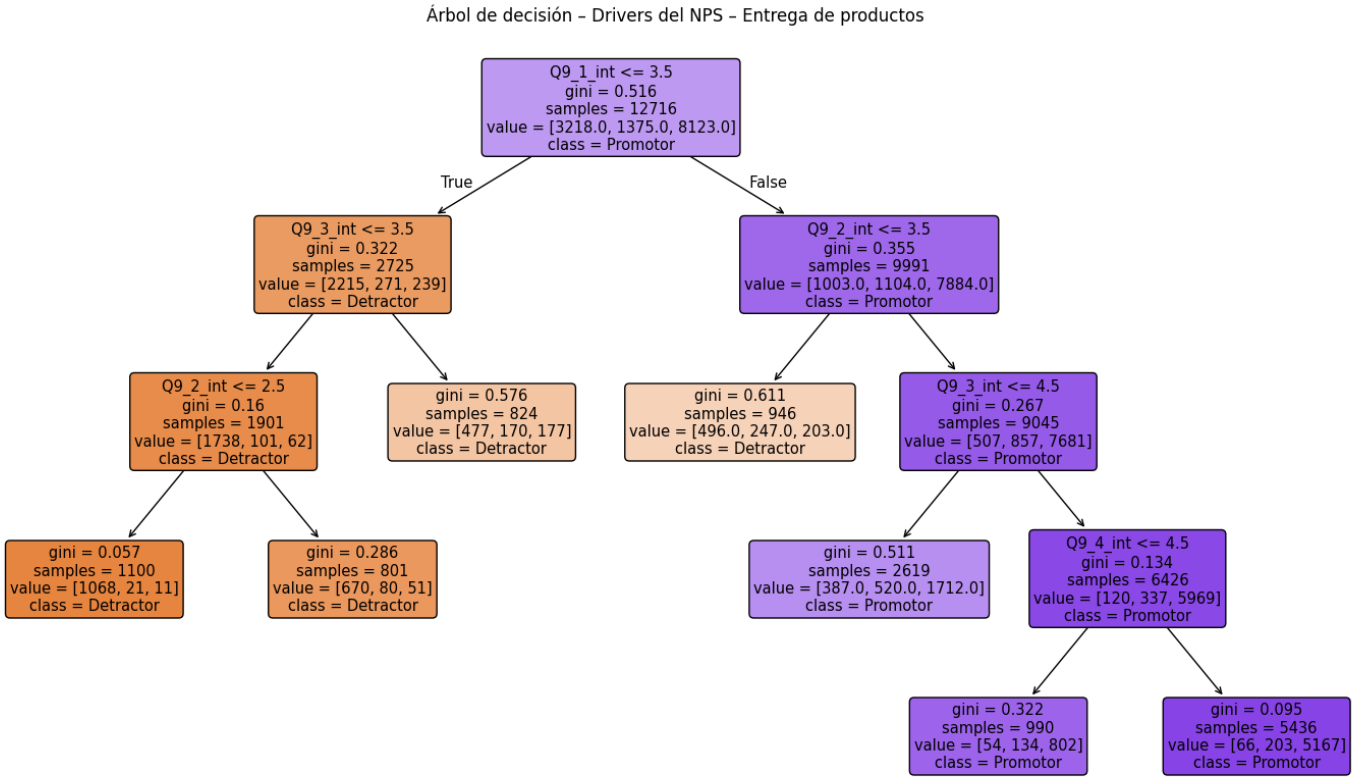

Figura 33

Árbol de decisión para el bloque de entrega de productos.

El árbol confirma que el cumplimiento en los tiempos de entrega ($Q9_1_int$) es la variable más poderosa para predecir el NPS. Si un cliente califica este aspecto con 3.5 o menos, el modelo lo clasifica mayoritariamente como Detractor (rama izquierda). Solo cuando la puntualidad es evaluada positivamente (> 3.5) se abre la posibilidad de ser Promotor. Dentro de esta rama favorable, la amabilidad del personal ($Q9_2_int$) actúa como el siguiente filtro clave para refinar la clasificación final. Esto refuerza el hallazgo central: en la experiencia de entrega, la puntualidad es la barrera de entrada y la cortesía es el factor que perfecciona la lealtad.

3.6 Algoritmo PC

El algoritmo PC aplicado sin restricciones produce un grafo bastante denso lo que sugiere una fuerte interdependencia entre los distintos MoT y el NPS. Este resultado es consistente con la naturaleza altamente correlacionada de las variables analizadas.

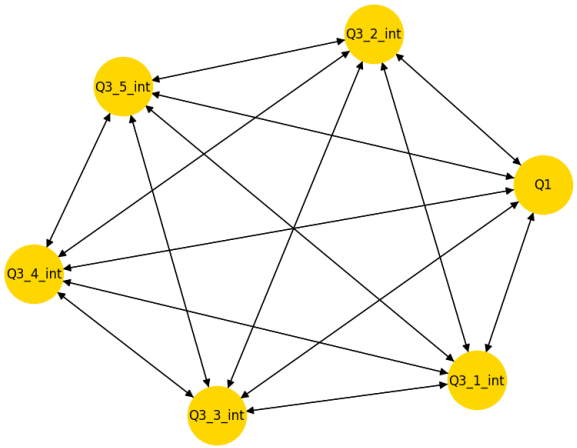

Figura 34
DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando chi-square

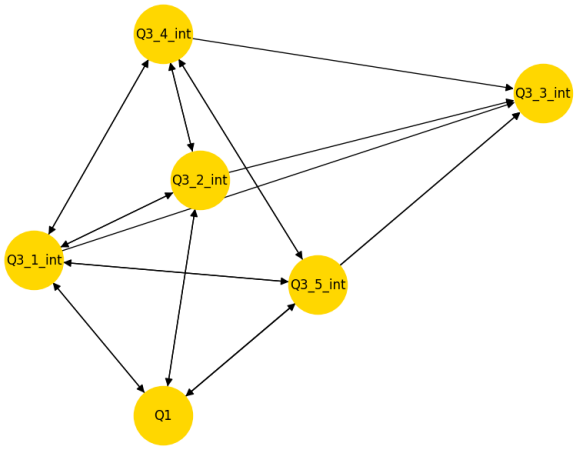

Figura 35
DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando gcm

Como observamos en las anteriores gráficas, este DAG se convierte en un gráfico complejo que no deja muy claro qué variables causan a otras, y simplemente muestra que la mayoría se causan unas a las otras. Esto, como ya se había mencionado anteriormente,

se debe a que el algoritmo PC realiza un test de correlación y, como ya hemos observado anteriormente, estas variables están altamente correlacionadas entre sí, y a pesar de que se usan diferentes test, el resultado sigue sin ser concluyente.

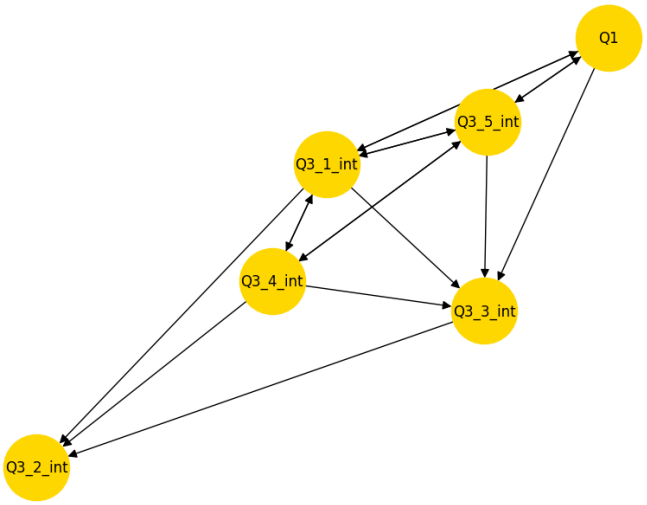

Figura 36
DAGs (Gráficos Acíclicos Dirigidos) de la causalidad entre MoT y NPS, usando pearson

A pesar de esto, al usar el test de dependencia relacional de Pearson, se obtuvo un resultado más satisfactorio en donde se observó que las variables causantes del comportamiento del NPS son Entrega de productos y Búsqueda y selección de productos.

4 Conclusiones

El presente estudio permitió identificar de manera cuantitativa y estructurada los principales impulsores del Net Promoter Score (NPS) en el contexto omnicanal del Grupo Éxito. A continuación, se sintetizan las conclusiones más relevantes:

1. La Experiencia de Entrega es el Determinante Crítico de la Lealtad. El análisis multivariado y los modelos predictivos coinciden en señalar al Momento de Verdad (MoT) "Entrega de productos" como la variable de mayor impacto en el NPS. Este momento no solo presenta la mayor importancia en los modelos, sino que también muestra la polarización más marcada en sus calificaciones: los clientes otorgan evaluaciones extremas (1 o 5), evitando neutralidad. Aspectos específicos como el cumplimiento de los tiempos y la amabilidad del personal son los principales impulsores dentro de este bloque. Una falla en la entrega es, por tanto, el camino más rápido hacia la creación de un detractor.

2. La Estructura Jerárquica de la Encuesta es Válida y Complementaria. El Análisis de Componentes Principales (PCA) confirmó que los aspectos específicos dentro de cada MoT comparten una dimensión latente coherente (explicando entre el 75 % y 85 % de la varianza). Sin embargo, la correlación entre estas representaciones latentes y la calificación directa del MoT fue baja, indicando que la evaluación global captura información adicional no contenida en los aspectos medidos. Esto valida la utilidad de mantener ambos niveles de medición (MoT y aspectos) para una comprensión completa de la experiencia.

3. Los Modelos Predictivos son Robustos e Interpretables. Los modelos de Histogram Gradient Boosting demostraron un alto desempeño predictivo, tanto en clasificación (NPS categórico) como en regresión (calificación de MoT). El uso de técnicas de interpretabilidad como SHAP y importancia por permutación permitió trascender la çaja negraz extraer reglas accionables. Estas técnicas revelaron la preponderancia de la Entrega y el Pago como los factores más influyentes, mientras que aspectos relacionados con la búsqueda de productos y los precios tuvieron un impacto más moderado y contextual.

4. El Desempeño Predictivo es Consistente y Generalizable. Los modelos de regresión para predecir la calificación de cada MoT a partir de sus aspectos mostraron métricas sólidas (R^2 entre 0.63 y 0.79 en el conjunto de prueba), con diferencias mínimas entre entrenamiento y prueba, lo que indica una generalización efectiva y ausencia de sobreajuste severo. El modelo para Entrega de productos obtuvo el R^2 más alto (0.7856), subrayando nuevamente que es el momento más estructurado y predecible de la experiencia.

5. La aplicación del algoritmo PC para el descubrimiento causal generó un grafo denso de interrelaciones entre los MoT y el NPS. Esto evidencia que la lealtad del cliente no es el resultado de un solo factor aislado, sino de una red de experiencias interdependientes. Una intervención aislada en un punto del recorrido puede tener efectos limitados si no se considera su interacción con otros momentos.

6. Existen Oportunidades Claras de Mejora Priorizadas. Los árboles de decisión permitieron traducir los hallazgos estadísticos en reglas simples y comunicables:

- Si la entrega es calificada ≤ 3.5, el cliente tiene alta probabilidad de ser Detractor.

- La facilidad de pago es la barrera crítica en el momento transaccional.

- La facilidad para encontrar productos es el filtro principal en la etapa de búsqueda.

Estas reglas permiten priorizar acciones: primero, garantizar una entrega puntual y amable; segundo, simplificar al máximo el proceso de pago; y tercero, optimizar la usabilidad y navegación en los canales digitales.

7. La combinación de técnicas estadísticas clásicas (ACM, PCA) con aprendizaje automático interpretable (Gradient Boosting, SHAP, árboles) demostró ser un marco metodológico que no solo logra predecir, sino también explicar lo que es fundamental para convertir insights en acciones estratégicas en un entorno empresarial.

En síntesis, este trabajo confirma que en el retail omnicanal la última milla es la primera prioridad. La lealtad del cliente se gana o se pierde en la puntualidad y calidad de la entrega, respaldada por transacciones fluidas y una experiencia digital intuitiva. Los hallazgos proporcionan un mapa basado en datos, para dirigir inversiones y esfuerzos operativos donde realmente impactan la percepción y la recomendación.

5 Recomendaciones

La optimización de la experiencia del cliente y del NPS requiere intervenciones específicas y medibles. Las siguientes recomendaciones se derivan directamente de los hallazgos del análisis:

1. Optimización de la experiencia de entrega. Se recomienda priorizar el cumplimiento de los tiempos de entrega y la calidad de la interacción con el personal de reparto. La implementación de un sistema de monitoreo en tiempo real y programas de capacitación y reconocimiento para los repartidores pueden generar mejoras significativas en este momento crítico.

2. Es fundamental garantizar un flujo de pago digital intuitivo y libre de fricciones, así como la coherencia absoluta entre el precio exhibido y el cobrado. La automatización de validaciones y un diseño centrado en el usuario son estrategias clave para esta área.

3. La inversión en la optimización de la funcionalidad de búsqueda, la precisión de la información de inventario y la claridad de la comunicación de precios en los canales digitales ayudará a mejorar la percepción durante la fase de búsqueda y selección.

4. Adopción de un sistema de gestión basado en datos. La integración de dashboards que visualicen los drivers del NPS en tiempo real y el uso de reglas derivadas de los modelos (como los árboles de decisión) para activar protocolos de recuperación permitirán una gestión más ágil y fundamentada.

5. Implementación de un enfoque colaborativo. La creación de equipos interdepartamentales (CX, Logística, TI) facilitará abordar de manera integral los momentos de verdad, reconociendo su interdependencia sistémica.

6. Establecimiento de un ciclo de mejora continua. La revisión periódica del desempeño de las iniciativas implementadas, respaldada por nuevos datos y análisis, permitirá ajustar las estrategias y mantener su efectividad en el tiempo.

Referencias

Agresti, A. (2010). *Analysis of Ordinal Categorical Data*. Wiley Series in Probability and Statistics. Wiley.

Fader, P. S. and B. G. Hardie (2009). *Journal of Interactive Marketing*. *23*(1), 61–69. Anniversary Issue.

Friedman, J. H. (2001). *The Annals of Statistics*. *29*(5), 1189–1232.

Greenacre, M. (2017). *Correspondence analysis in practice* (3 ed.). Boca Raton: CRC Press.

Hastie, T. (2009, 01). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2 ed.). Springer.

Jolliffe, I. T. and J. Cadima (2016). *Philosophical Transactions of the Royal Society A*. *374*(2065), 20150202.

Lemon, K. N. and P. C. Verhoef (2016). *Journal of Marketing*. *80*(6), 69–96.

Lundberg, S. M. and S.-I. Lee (2017). A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, NIPS'17, Red Hook, NY, USA, (pp. 4768–4777). Curran Associates Inc.

Parasuraman, A., V. A. Zeithaml, and L. L. Berry (1988). *Journal of Retailing*. *64*(1), 12–40.

Pearl, J. (2000). *Causality: Models, Reasoning, and Inference*. Cambridge University Press.

Reichheld, F. F. (2003). *Harvard Business Review*. *81*(12), 46–54.

Anexos