



Facultad de Ciencias Económicas y Empresariales

ICADE

**ESTRATEGIAS DE FIDELIZACIÓN EN
APPS DE FOOD DELIVERY: IMPACTO
EN LA RENTABILIDAD Y RETENCIÓN
DE CLIENTES**

Clave: 202010667

Autor: Jaime Ramón Sol Arce

Directora: M.ª José Martín Rodrigo

MADRID | Abril 2025

Resumen

Este Trabajo de Fin de Grado analiza el impacto de las estrategias promocionales —en particular los descuentos— y de las comisiones cobradas a los restaurantes sobre la fidelización de clientes y la rentabilidad de las plataformas de *food delivery*. Para ello, se emplea una metodología mixta: un enfoque cualitativo basado en entrevistas con expertos del sector y una revisión de literatura, junto con un análisis cuantitativo basado en modelos de regresión con validación cruzada aplicados a datos transaccionales de Zomato en Nueva Delhi. Los resultados revelan que, si bien los descuentos pueden atraer usuarios a corto plazo, no garantizan su fidelización y, en algunos casos, reducen los márgenes de beneficio. Asimismo, las comisiones —tanto fijas como porcentuales— afectan significativamente la rentabilidad, con un impacto desigual según el valor del pedido. La aplicación de modelos predictivos (Random Forest, XGBoost, LightGBM y Redes Neuronales) permitió identificar las variables clave para definir descuentos y comisiones óptimos, aportando evidencia para una gestión más dinámica y segmentada. En conjunto, el estudio destaca la necesidad de evolucionar hacia estrategias personalizadas de fidelización, como programas de suscripción y el uso de inteligencia artificial para predecir la demanda. Estas herramientas permiten a las plataformas de *food delivery* optimizar sus costes sin comprometer la experiencia del usuario, mejorando así la retención de clientes y la rentabilidad a largo plazo.

Palabras Clave: plataformas de *food delivery*, fidelización de clientes, rentabilidad, descuentos, modelos predictivos, *machine learning*.

Abstract

This Bachelor's Thesis analyzes the impact of promotional strategies—particularly discounts—and the commission fees charged to restaurants on customer retention and profitability within food delivery platforms. A mixed-methods approach was adopted, combining a qualitative analysis based on expert interviews and a literature review, with a quantitative analysis using regression models with cross-validation applied to transactional data from Zomato in New Delhi. The results show that although discounts can be effective in attracting users in the short term, they do not guarantee long-term customer loyalty and may, in some cases, reduce profit margins. Likewise, commission fees—both fixed and percentage-based—have a significant effect on profitability, with a differentiated impact depending on order value and transaction size. The implementation of predictive models (Random Forest, XGBoost, LightGBM, and Neural Networks) made it possible to identify the key variables involved in determining optimal discount and commission levels, offering strong evidence to support more dynamic and segmented decision-making. Overall, the study highlights the need to shift toward personalized customer retention strategies, such as subscription programs and the application of artificial intelligence for demand forecasting. These tools enable food delivery platforms to optimize their cost structures without compromising the user experience, ultimately enhancing customer retention and ensuring long-term financial sustainability.

Keywords: food delivery platforms, customer loyalty, profitability, discounts, predictive models, machine learning.

Índice de la Memoria

1. Introducción	10
1.1. Contexto	10
1.2. Justificación del estudio	11
1.3. Preguntas de investigación y objetivos	12
2. Revisión de la Literatura	15
2.1. Innovación digital y COVID-19	15
2.2. Impacto en los restaurantes	16
2.3. Satisfacción y fidelización de clientes	17
2.4. Rentabilidad y modelos de negocio	18
2.5. Estrategias de retención y programas de recompensas	19
2.6. Relación entre fidelización y rentabilidad	20
2.7. Gaps en la literatura	22
2.8. Resumen de la revisión de la literatura	23
3. Metodología	35
3.1. Metodología cualitativa	35
3.1.1. Revisión de la literatura.....	35
3.1.2. Entrevistas a expertos	36
3.2. Metodología cuantitativa	36
3.2.1. Fuente de datos	36
3.2.2. Métodos de análisis	37
3.2.3. Validación y evaluación	37
4. Análisis de Datos	37
4.1. Introducción al análisis exploratorio de datos	38
4.2. Carga, limpieza y preparación de datos	38
4.2.1. Carga de datos y estructura inicial.....	38
4.2.2. Conversión de rupias indias a euros	40
4.2.3. Extracción y conversión de descuentos	40
4.2.4. Conversión de costes y cálculo de rentabilidad.....	41
4.2.5. Transformación de fechas y creación de variables temporales	42
4.3. Detección y Tratamiento de Valores Atípicos	43

4.4.	Análisis de correlación entre variables	51
4.5.	Análisis descriptivo	52
4.5.1.	Estadísticas generales de los datos	52
4.5.2.	Compartimiento de los clientes y pedidos.....	56
4.5.3.	Descuentos: análisis y efecto en la rentabilidad.....	60
4.5.4.	Métodos de pago: comparativa e impacto financiero.....	68
4.5.5.	Rentabilidad y estrategia de los restaurantes de la plataforma.....	70
4.6.	Conclusiones del análisis exploratorio	72
5.	<i>Desarrollo y Validación del Modelo Matemático.....</i>	73
5.1.	Desarrollo del modelo	73
5.1.1.	Selección de variables	73
5.1.2.	Modelos utilizados.....	74
5.2.	Validación y evaluación del modelo	74
5.2.1.	Validación cruzada	74
5.2.2.	Comparación de resultados.....	74
5.3.	Interpretabilidad y explicabilidad.....	75
5.4.	Conclusiones y aplicabilidad del modelo	80
6.	<i>Estrategias de Fidelización y Promoción en Food Delivery.....</i>	81
6.1.	Personalización inteligente de descuentos.....	81
6.2.	Programas de fidelización y beneficios exclusivos	82
6.3.	Exclusividad de la oferta y diferenciación	82
6.4.	Inteligencia artificial para la optimización de la retención.....	83
6.5.	Contraste entre modelos y expertos del sector	83
6.6.	Conclusiones y aplicabilidad.....	84
7.	<i>Conclusiones y Trabajo Futuro</i>	85
7.1.	Limitaciones del estudio	85
7.2.	Recomendaciones y líneas de investigación futura	86
8.	<i>Bibliografía.....</i>	88
9.	<i>Anexos.....</i>	93
10.	<i>Declaración de Uso de Herramientas de IAG</i>	97

Índice de Tablas

Tabla 1. Objetivos, acciones y resultados del modelo de fidelización en food delivery	14
Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery	25
Tabla 3. Estadísticas descriptivas de las variables numéricas.....	39
Tabla 4. Comparación entre pedidos rentables y pedidos con rentabilidad > -100%.....	68
Tabla 5. Comparación de modelos y métricas de rendimiento	75
Tabla 6. Validación de estrategias de fidelización: opiniones de expertos en food delivery.....	84
Tabla 7. Síntesis de estrategias y aplicabilidad en food delivery.....	85
Tabla 8. Cuadro resumen de entrevistas	94

Índice de Ilustraciones

Ilustración 1. Columnas y tipos de datos del dataset.....	38
Ilustración 2. Mapa de calor para la identificación de valores nulos en el conjunto de datos ...	39
Ilustración 3. Ejemplo de conversión de rupias indias (INR) a euros (EUR)	40
Ilustración 4. Conversión de descuentos en INR a EUR y cálculo del descuento total para estandarizar el impacto financiero en la rentabilidad de la plataforma.....	41
Ilustración 5. Conversión de costes a EUR y cálculo del beneficio neto, considerando descuentos, comisiones e ingresos totales por pedido	41
Ilustración 6. Análisis de reembolsos y su efecto en la rentabilidad de la plataforma.....	42
Ilustración 7. Transformaciones temporales: cálculo de duración de pedidos y categorización por día y momento del día.....	43
Ilustración 8. Boxplot de la tasa de comisión (%): Identificación de valores atípicos.....	44
Ilustración 9. Relación entre el valor del pedido y la tasa de comisión (%)	45
Ilustración 10. Resultados de la regresión línea simple	46
Ilustración 11. Regresión lineal: tasa de comisión (%) vs. valor del pedido.....	46
Ilustración 12. Resultados de la regresión logarítmica.....	47
Ilustración 13. Regresión logarítmica: tasa de comisión (%) vs. valor del pedido	48
Ilustración 14. Resultados de la regresión polinómica (grado 2)	49
Ilustración 15. Regresión polinómica: tasa de comisión (%) vs. valor del pedido	49
Ilustración 16. Resultados de la regresión no lineal (inversa).....	50
Ilustración 17. Regresión no lineal inversa: tasa de comisión (%) vs. valor del pedido	51
Ilustración 18. Mapa de calor de correlaciones (variables filtradas).....	52
Ilustración 19. Comparación de ingresos, costes y beneficios Totales	53
Ilustración 20. Evolución temporal de pedidos y rentabilidad.....	54
Ilustración 21. Distribución de costes, ingresos y beneficio	54
Ilustración 22. Distribución de costes totales	55
Ilustración 23. Distribución de descuentos por tipo	56
Ilustración 24. Impacto de los descuentos en la retención de clientes	57
Ilustración 25. Distribución del AOV según el tipo de cliente.....	57

Ilustración 26. Evolución del AOV en clientes recurrentes	58
Ilustración 27. Distribución del Profit Margin (%) según tipo de cliente	59
Ilustración 28. Evolución del Profit en clientes recurrentes.....	59
Ilustración 29. Frecuencia de tipos de descuento por día de la semana	60
Ilustración 30. Frecuencia de tipos de descuento por franja horaria	60
Ilustración 31. Rentabilidad promedio por tipo de descuento y día de la semana	61
Ilustración 32. Margen de Beneficio Medio según el Día de la Semana	62
Ilustración 33. Rentabilidad promedio por tipo de descuento y franja horaria	62
Ilustración 34. Margen de Beneficio Medio por Franja Horaria	63
Ilustración 35. Impacto del tipo de descuento en la rentabilidad	64
Ilustración 36. Impacto del tipo de descuento en el AOV.....	65
Ilustración 37. Mapa de calor: relación entre descuento y rentabilidad	65
Ilustración 38. Distribución del Profit Margin (%)	66
Ilustración 39. Distribución de tipos de descuento en pedidos con rentabilidad < -100%.....	67
Ilustración 40. Rentabilidad promedio por método de pago	69
Ilustración 41. Coste medio de procesamiento por método de pago.....	70
Ilustración 42. Comparación de rentabilidad entre los 30 restaurantes con más pedidos	71
Ilustración 43. Comparación de rentabilidad entre los 30 restaurantes con mayor beneficio....	71
Ilustración 44. SHAP summary plot - Random Forest (Commission Rate (%))	76
Ilustración 45. SHAP summary plot - Random Forest (Discount Rate (%))	76
Ilustración 46. SHAP summary plot - XGBoost (Commission Rate (%))	77
Ilustración 47. SHAP summary plot - XGBoost (Discount Rate (%)).....	77
Ilustración 48: SHAP summary plot - Red Neuronal (Commission Rate (%))	78
Ilustración 49. SHAP summary plot - Red Neuronal (Discount Rate (%)).....	78
Ilustración 50. SHAP summary plot - LightGBM (Commission Rate (%))	79
Ilustración 51. SHAP summary plot - LightGBM (Discount Rate (%)).....	79

Índice de Ecuaciones

Ecuación 1. Modelo lineal de comisión (%).....	46
Ecuación 2. Modelo logarítmico de comisión (%).....	47
Ecuación 3. Modelo polinómico de comisión (%).....	48
Ecuación 4. Modelo inverso de comisión (%).....	50

1. Introducción

En un mundo cada vez más digitalizado, las plataformas de *food delivery* se han convertido en actores clave de la economía global, transformando los hábitos de consumo y los modelos de negocio en el sector alimentario. Estos servicios han evolucionado rápidamente, pasando de ser una comodidad ocasional a convertirse en una necesidad estratégica para los restaurantes, especialmente durante la pandemia del COVID-19. El presente trabajo busca enmarcar esta transformación en un análisis crítico, explorando los factores que han impulsado este crecimiento, así como los desafíos y oportunidades que surgen en un sector donde la fidelización de los clientes y la rentabilidad son objetivos esenciales y, a menudo, complejos de equilibrar.

1.1.Contexto

La pandemia del COVID-19 marcó un punto de inflexión en la adopción de tecnologías digitales a nivel global, acelerando la transformación de modelos de negocio tanto en empresas grandes como en pequeñas y medianas organizaciones (Amankwah-Amoah et al., 2021; Härmand, 2021). Para muchas compañías, incluidas las dedicadas al *food delivery*, la digitalización se convirtió en un factor determinante para mantener la operatividad durante las restricciones y confinamientos (Scarlat et al., 2022).

En el ámbito de la restauración, este proceso de digitalización reforzó el papel de las plataformas de *food delivery* como soluciones capaces de sostener la actividad de los restaurantes, incluso en circunstancias adversas (Zhang & Ha, 2024). No obstante, la crisis sanitaria también evidenció brechas digitales y desigualdades competitivas, favoreciendo a los establecimientos más habituados a operar en entornos virtuales frente a aquellos con menor experiencia (Raj et al., 2023; Scarlat et al., 2022). Estos contrastes, junto con cambios en las preferencias de los consumidores, impulsaron un crecimiento notable del sector, estimado en 112,48 mil millones de dólares en 2024, con una proyección de 213,44 mil millones de dólares en 2030 (Curry, 2025).

En este escenario, la satisfacción del cliente, en términos de calidad de los alimentos y eficiencia en la entrega, ha cobrado mayor relevancia. Estudios recientes muestran que la experiencia positiva en una plataforma de *delivery* potencia la recurrencia de los usuarios, pero también se han observado dificultades para sostener el crecimiento cuando los costes operativos aumentan o las comisiones son demasiado elevadas (Caridi, 2021; Lempert, 2023; Ruslan et al., 2024). De esta manera, los retos ligados a la sostenibilidad financiera se han convertido en un eje central para entender el futuro de las plataformas de *food delivery*, especialmente en lo relacionado con la interacción entre las estrategias promocionales y la rentabilidad.

Ante estas transformaciones, el presente estudio aborda cómo las estrategias promocionales (con énfasis en los descuentos) y las comisiones cobradas a los restaurantes impactan en la retención de clientes y la sostenibilidad económica de las plataformas de *food delivery*. Más allá de reflejar la evolución del sector, el objetivo es proponer recomendaciones prácticas que equilibren la fidelización de los usuarios con la rentabilidad del negocio, en un mercado cada vez más competitivo.

1.2. Justificación del estudio

La consolidación del *food delivery* como un servicio esencial en la economía digital ha visibilizado la necesidad de analizar en profundidad las dinámicas de rentabilidad y de la fidelización de clientes. Si bien la pandemia del COVID-19 favoreció la adopción y el uso intensivo de estas plataformas, también incrementó la competencia entre restaurantes y la presión sobre los márgenes de beneficio (Raj et al., 2023). En este marco, entender cómo las estrategias de promoción, particularmente los descuentos, y la estructura de comisiones inciden en el desempeño financiero se ha vuelto determinante para definir la sostenibilidad de estas empresas a mediano y largo plazo.

Las cadenas de restaurantes, por su volumen de pedidos y recursos, suelen aprovechar más las plataformas de *delivery*, experimentando incluso un efecto multiplicador en la visibilidad y el volumen de ventas (Li & Wang, 2024). No obstante, los restaurantes independientes también registran un incremento en la llegada de comensales gracias a la difusión que otorgan dichas plataformas, lo que plantea un escenario de oportunidades, pero con altas comisiones que pueden alcanzar hasta el 25% del pedido (Chen et al., 2022). Este modelo de negocio ha llevado a cuestionamientos sobre la rentabilidad de los descuentos masivos y su efecto real en la retención de clientes.

En consecuencia, investigar el equilibrio entre la necesidad de fidelizar a los usuarios mediante promociones y la optimización de los costes se convierte en un eje central para los restaurantes y las plataformas de *delivery*. Un enfoque basado en datos, utilizando análisis cuantitativo y herramientas de *machine learning*, permite abordar esta problemática con una mayor exactitud. Por tanto, este estudio profundiza en preguntas clave sobre el impacto de las promociones y las comisiones en la retención de usuarios y la rentabilidad, estableciendo objetivos específicos que orientan el análisis y la propuesta de estrategias sostenibles.

La creciente competitividad en el sector hace imprescindible el desarrollo de enfoques innovadores que vinculen las decisiones de *pricing* con la mejora de la experiencia del cliente, considerando la adopción de tecnologías avanzadas y la evolución de las demandas del mercado. Así, este trabajo busca contribuir con un marco analítico que no solo evalúe la eficacia de los

descuentos y las comisiones, sino que también identifique oportunidades de crecimiento sostenible a través de programas de fidelización, suscripciones y alianzas estratégicas con los restaurantes.

De este modo, la presente investigación busca cubrir vacíos en la literatura sobre la relación entre fidelización y rentabilidad, aportando evidencia práctica que oriente la toma de decisiones de las plataformas. A continuación, se presentan las preguntas de investigación y los objetivos que estructuran el análisis teórico y empírico del estudio.

1.3.Preguntas de investigación y objetivos

Dado todo lo expuesto en los apartados anteriores, resulta esencial sistematizar las cuestiones clave que surgen en torno a las estrategias promocionales, la fidelización de clientes y la rentabilidad en las plataformas de *food delivery*. Por ello, se han definido preguntas de investigación y objetivos específicos que orientan el análisis y vinculan tanto la visión teórica como la investigación empírica de este trabajo. A continuación, se presentan los objetivos generales y específicos que guían el desarrollo del resto de secciones.

Objetivo General

Evaluar cómo las estrategias promocionales (principalmente, los descuentos) y la estructura de comisiones (fuente clave de ingresos) inciden en la fidelización de usuarios y en la rentabilidad de las plataformas de *food delivery*, con el fin de proponer mejoras que optimicen su sostenibilidad financiera.

Objetivo Específicos

1. Cuantificar el impacto de los descuentos en la retención de clientes

- Determinar si los descuentos aplicados (fijos o en porcentaje) afectan de manera significativa la recompra y el comportamiento de los usuarios.

2. Examinar la relación entre la tasa de comisión y la rentabilidad de la plataforma

- Analizar cómo las comisiones, que representan los ingresos de la plataforma al cobrar por la intermediación, afectan el margen de beneficio y a la satisfacción de los restaurantes.

3. Desarrollar modelos predictivos para explicar y anticipar las tasas de descuento y de comisión

- Implementar algoritmos de *machine learning* (Random Forest, XGBoost, LightGBM, Redes Neuronales) para identificar qué factores (*Order Value, Profit*

Margin, Delivery Time, Rentable) determinan las variaciones en *Discount Rate (%)* y *Commission Rate (%)*.

4. Examinar la interacción entre descuentos y comisiones en la rentabilidad global

- Investigar cómo la combinación de ambos factores influye en el margen de beneficio de la plataforma, sin pretender establecer configuraciones óptimas definitivas.

5. Proponer mejoras prácticas en la gestión de promociones y estructura de comisiones

- Formular recomendaciones, sustentadas en la evidencia estadística y en modelos predictivos, que permitan a las plataformas equilibrar la retención de usuarios con la sostenibilidad económica.

Los objetivos planteados establecen una hoja de ruta para analizar la relación entre promociones, fidelización y rentabilidad en las plataformas de *delivery*. A continuación, se presenta en la Tabla 1 una síntesis que vincula cada objetivo específico con el modo en que se aborda, las variables empleadas y el resultado esperado. Esta sistematización permite visualizar de manera estructurada la contribución de cada objetivo al desarrollo del trabajo y su alineación con las metodologías cualitativas y cuantitativas descritas.

Tabla 1. *Objetivos, acciones y resultados del modelo de fidelización en food delivery*

Objetivo	Acciones realizadas	Métricas del Modelo	Resultado esperado	Estado
1. Cuantificar el impacto de los descuentos en la retención de clientes	<ul style="list-style-type: none"> Análisis estadístico de la tasa de retención (Chi-cuadrado, t-test) Comparación de pedidos con y sin descuentos Segmentación de clientes nuevos vs. recurrentes 	<ul style="list-style-type: none"> Discount Rate (%) Discount Amount EUR Rentable (indicador binario) Retención de clientes 	Determinar si los descuentos (fijos o en %) contribuyen a la fidelización o atraen únicamente a clientes "oportunistas"	Alcanzado
2. Analizar la relación entre las tasas de comisión y la rentabilidad de la plataforma	<ul style="list-style-type: none"> Modelado de la estructura de comisiones (regresión lineal, logarítmica, polinómica) Detección de outliers en la 'Commission Rate (%)' Evaluación de márgenes 	<ul style="list-style-type: none"> Commission Rate (%) Profit Margin (%) Order Value EUR Costes Totales 	Establecer qué tipo de comisión genera una mayor rentabilidad y en qué rangos de pedido	Alcanzado
3. Desarrollar modelos predictivos para explicar y anticipar Discount Rate (%) y Commission Rate (%)	<ul style="list-style-type: none"> Entrenamiento de algoritmos de Machine Learning (Random Forest, XGBoost, LightGBM, Redes Neuronales) Evaluación de métricas (MAE, RMSE, R²) Explicabilidad (SHAP) 	<ul style="list-style-type: none"> Discount Rate (%) Commission Rate (%) Order Value EUR Delivery Time (min) Profit Margin (%) 	Determinar los factores críticos que motivan la fijación de descuentos y comisiones y mejorar la precisión predictiva	Alcanzado
4. Examinar la interacción entre descuentos y comisiones en la rentabilidad global	<ul style="list-style-type: none"> Evaluación conjunta de las variables Discount Rate (%) y Commission Rate (%) mediante correlaciones y segmentaciones Aplicación de modelos predictivos (Random Forest, XGBoost, LightGBM, Redes Neuronales) para estimar la influencia combinada de ambas tasas en la rentabilidad. 	<ul style="list-style-type: none"> Discount Rate (%) Commission Rate (%) Profit Order Value EUR Rentable 	Identificar qué promociones minimizan las pérdidas y maximizan la utilidad, aportando criterios para ajustar campañas	Alcanzado
5. Proponer mejoras prácticas en la gestión de promociones y comisiones	<ul style="list-style-type: none"> Revisión de hallazgos (análisis descriptivo + modelos predictivos) Contrastación con la literatura y entrevistas a expertos Diseño de recomendaciones finales 	<ul style="list-style-type: none"> Profit Margin (%) Discount Rate (%) Commission Rate (%) Umbrales óptimos de Order Value 	Diseñar estrategias basadas en datos que sustituyan descuentos masivos por mecanismos de fidelización más rentables y sostenibles	Alcanzado

En la siguiente sección, se revisa la literatura existente para consolidar el marco teórico y contextualizar las estrategias que posteriormente se analizarán empíricamente.

2. Revisión de la Literatura

La digitalización ha transformado radicalmente el sector del *food delivery*, impulsada en gran medida por la pandemia del COVID-19. Esta evolución ha redefinido los modelos de negocio y ha dado lugar a nuevas oportunidades, pero también plantea desafíos financieros y operativos. En particular, la sostenibilidad de las plataformas depende en gran medida de la fidelización de clientes y de estrategias que equilibren la retención con la rentabilidad. Para comprender estas dinámicas, este capítulo examina la literatura existente sobre el impacto de la digitalización, la relación entre satisfacción y fidelización, y los modelos de negocio en el sector. Asimismo, se analizan estrategias de retención y programas de recompensas, identificando vacíos en la investigación que justifican un análisis más profundo de la interacción entre fidelización y sostenibilidad financiera.

2.1. Innovación digital y COVID-19

La literatura sobre innovación digital resalta cómo la pandemia del COVID-19 impulsó de manera significativa la digitalización, generando tanto oportunidades como desafíos en distintos sectores. Autores como Scarlat et al. (2022), Amankwah-Amoah et al. (2021) y Härmand (2021) destacan cómo las economías globales experimentaron una rápida aceleración en la adopción de tecnologías digitales durante la crisis sanitaria, modificando tanto el comportamiento de las empresas como el de los consumidores. Estos estudios también examinan el incremento en la inversión tecnológica y la evolución hacia un entorno cada vez más digitalizado, a la vez que señalan las desigualdades y desafíos que surgieron en este proceso. En el caso de las plataformas de *delivery*, esta transformación tecnológica marcó un cambio estructural que facilitó su crecimiento exponencial, pero también planteó preguntas sobre su sostenibilidad financiera y operativa.

En esta misma línea, Hajder (2023) analiza el impacto de la pandemia en la implementación de innovaciones tecnológicas dentro del marco de la Industria 4.0. Su estudio destaca que la crisis sanitaria no solo aceleró la transformación digital en múltiples sectores, sino que también puso en evidencia la importancia de la innovación como factor clave para la competitividad y el desarrollo económico. En particular, subraya que el desarrollo de la Industria 4.0 ha sido impulsado por la creciente necesidad de automatización, digitalización y optimización de procesos, elementos que se han convertido en una ventaja competitiva esencial para las empresas en un mercado globalizado.

En consonancia con estos avances, la digitalización ha impulsado el crecimiento de las plataformas de *food delivery* al optimizar la eficiencia operativa y mejorar la experiencia del usuario mediante la automatización y el análisis de datos (Garay Freire & Álvarez Reyes, 2024). No obstante, su implementación afronta desafíos como altos costes, resistencia organizacional y desigualdad en la adopción, lo que ha generado impactos diferenciados entre restaurantes pequeños y grandes (Naranjo-Armijo & Almeida-Blacio, 2024).

Comprender y abordar estos retos es clave para aprovechar la innovación digital. Sin embargo, su adopción no ocurre de manera aislada, sino que su impacto varía según la estructura y capacidad de adaptación de los actores involucrados. En el sector del *food delivery*, los restaurantes han sido particularmente afectados por la digitalización, enfrentando tanto oportunidades como desafíos en términos de costos operativos, dependencia de plataformas y rentabilidad. A continuación, se analiza cómo estas plataformas han transformado la dinámica de los restaurantes, influyendo en sus estrategias comerciales y sostenibilidad financiera.

2.2. Impacto en los restaurantes

En cuanto al impacto de las plataformas de *delivery* en los restaurantes, la literatura muestra una variedad de perspectivas. Raj et al. (2023), Chen et al. (2022) y Li y Wang (2024) exploran cómo estas plataformas han influido en la rentabilidad y operatividad de los restaurantes, ya sean grandes cadenas o pequeños negocios. Por ejemplo, muchos restaurantes pequeños han luchado por adaptarse a las altas comisiones y los cambios en la dinámica de los pedidos, mientras que las cadenas más grandes han logrado capitalizar la tecnología para expandirse. Este dualismo refleja la necesidad de estrategias adaptativas para asegurar la sostenibilidad.

Además, un estudio realizado por Van Veldhoven et al. (2021) centrado en el impacto de Deliveroo en restaurantes belgas entre 2010 y 2018 encontró que, si bien las plataformas de *delivery* pueden mejorar ciertos aspectos financieros de los restaurantes, los beneficios no siempre son claros a largo plazo. La liquidez de los restaurantes aumentó significativamente tras asociarse con la plataforma, lo que sugiere que la mayor exposición y volumen de pedidos generados a través de estos servicios pueden mejorar el flujo de caja en el corto plazo. Sin embargo, no se halló evidencia concluyente de que la rentabilidad (ROA) o la solvencia financiera mejoraran con la adopción del servicio de *delivery*, lo que sugiere que los costes operativos adicionales y las comisiones cobradas por estas plataformas pueden limitar las ganancias netas.

Asimismo, el estudio destaca que los restaurantes, al depender de una plataforma externa para la gestión de pedidos y entregas, pierden control sobre aspectos clave del servicio, como la calidad de la entrega y la interacción directa con el cliente, lo que puede afectar la experiencia del consumidor y, en consecuencia, su fidelización. Esta pérdida de autonomía operativa representa

un desafío para los restaurantes, que deben evaluar cuidadosamente si la visibilidad y el volumen de pedidos que ofrecen estas plataformas compensan los costes asociados y el menor control sobre el servicio (Van Veldhoven et al., 2021).

Si bien las plataformas de *delivery* pueden ampliar el alcance y mejorar la liquidez de los restaurantes, también generan desafíos en términos de rentabilidad, sostenibilidad financiera y control operativo. Para enfrentar estos retos, los restaurantes deben adaptar sus estrategias según su estructura de costes, volumen de ventas y nivel de dependencia de estas plataformas. No obstante, la viabilidad financiera no solo depende de la relación entre restaurantes y plataformas, sino también de la percepción y comportamiento de los consumidores. La satisfacción del cliente y su fidelización son factores clave que determinan el éxito de estas plataformas, influyendo directamente en la recurrencia de uso y, en última instancia, en la rentabilidad del negocio. En la siguiente sección se analiza cómo la calidad del servicio y la percepción de valor impactan en la lealtad del usuario y en la sostenibilidad de las plataformas de *delivery*.

2.3. Satisfacción y fidelización de clientes

La satisfacción del cliente es un pilar fundamental en el éxito de las plataformas de *food delivery*, ya que influye directamente en la fidelización y, en última instancia, en la rentabilidad. Diversos estudios han identificado los principales factores que determinan la percepción del cliente en este sector, como la calidad de la comida, el tiempo de entrega, la facilidad de uso de las aplicaciones y la presentación del pedido (Ruslan et al., 2024; Sahoo et al., 2024; Zhang & Ha, 2024). Estos elementos no solo afectan la experiencia del usuario, sino que también condicionan su disposición a seguir utilizando el servicio.

En este contexto, la literatura ha identificado estrategias clave para fortalecer la fidelización en plataformas de *delivery*. La calidad del servicio electrónico, la percepción de valor y la satisfacción del cliente son factores determinantes en la lealtad y la intención de recompra (Donsuchit & Nuangjamnong, 2022). Estrategias como la personalización, los programas de recompensas y la generación de un valor emocional significativo han demostrado ser especialmente efectivas en plataformas como GoFood y GrabFood (Renaldi et al., 2024).

Desde una perspectiva teórica, la fidelización del cliente en plataformas de *delivery* sigue un proceso que involucra tanto factores racionales como emocionales. Lee y Han (2022) proponen un modelo en cuatro etapas, cognitiva, afectiva, conativa y conductual, donde la satisfacción inicial evoluciona progresivamente hasta convertirse en una lealtad consolidada. A su vez, la teoría de la Lealtad del Consumidor de Oliver (1999) sugiere que la repetición de experiencias satisfactorias es clave para generar un compromiso duradero con la marca. La Teoría de la Expectativa-Confirmación de Bhattacharjee refuerza esta idea al explicar que la continuidad en

el uso de un servicio depende de la comparación entre las expectativas iniciales y la utilidad percibida tras su consumo (Islam et al., 2017).

El modelo SERVQUAL, desarrollado por Parasuraman, identifica cinco dimensiones esenciales en la calidad del servicio: tangibilidad, confiabilidad, capacidad de respuesta, seguridad y empatía. Estas dimensiones influyen directamente en la percepción del cliente y, por ende, en su decisión de continuar usando una plataforma de *delivery* (Shi & Shang, 2020). En particular, la confiabilidad y la empatía juegan un papel clave en la satisfacción del usuario y su lealtad a largo plazo, ya que reflejan la capacidad de las plataformas para generar confianza y ofrecer un servicio personalizado y atento a las necesidades del consumidor (Arli et al., 2024). Finalmente, el marco de Innovación Disruptiva de Christensen explica cómo las plataformas de *delivery* han transformado la industria alimentaria al desafiar a los modelos tradicionales de distribución, un aspecto crucial para comprender las dinámicas de competencia en este mercado (Shi & Shang, 2020).

Si bien la satisfacción del cliente y su fidelización son pilares fundamentales para el éxito de las plataformas de *food delivery*, su impacto en la rentabilidad no es directo ni automático. Una alta retención de clientes puede contribuir al crecimiento del negocio, pero si las estrategias de fidelización generan costes excesivos o dependen demasiado de descuentos y promociones, su sostenibilidad financiera puede verse comprometida. Por ello, es esencial analizar cómo las plataformas equilibran la retención de usuarios con la optimización de costes y la generación de ingresos. La siguiente sección explora los modelos de negocio de estas plataformas, examinando cómo factores como las comisiones, la logística y la eficiencia operativa influyen en su viabilidad económica.

2.4. Rentabilidad y modelos de negocio

La rentabilidad sigue siendo uno de los mayores desafíos para las plataformas de *delivery*, ya que su modelo de negocio suele estar condicionado por márgenes ajustados y una alta dependencia del volumen de pedidos. Helgesen (2000) señala que, si bien la lealtad del cliente puede contribuir al crecimiento financiero, esta relación no es lineal y requiere un equilibrio óptimo entre satisfacción y fidelidad. Sin embargo, estudios recientes indican que muchas plataformas operan con pérdidas, dependiendo del capital de riesgo y alcanzando la sostenibilidad económica solo cuando superan ciertos volúmenes mínimos de transacciones (Alvarez-Palau et al., 2022).

Este escenario también afecta a los restaurantes, que se enfrentan a elevadas comisiones que reducen sus márgenes de ganancia y pueden generar tensiones contractuales (Feldman et al.,

2023). Ante esta situación, la necesidad de disminuir costes y mejorar la eficiencia se ha vuelto prioritaria tanto para las plataformas como para sus asociados.

En este sentido, Niu et al. (2021), analizan la influencia de la logística en la rentabilidad de restaurantes y plataformas, mostrando cómo la optimización de estrategias de reparto, ya sea con flotas propias o externalizadas, reduce costes operativos y mejora la eficiencia en la entrega. De forma complementaria, Addai et al. (2024) señalan que innovaciones en la gestión de entregas, como la optimización de rutas y la coordinación con los repartidores, no solo afectan positivamente la experiencia del cliente, sino que también pueden incrementar los beneficios económicos.

Sin embargo, estos esfuerzos logísticos y financieros deben abordarse de forma integral, ya que algunos modelos de *delivery* pueden plantear retos adicionales, como la prevención de enfermedades transmitidas por alimentos (Addai et al., 2024). Pese a la amplitud de investigaciones sobre la relación entre costes operativos, logística y rentabilidad, persiste un vacío en el análisis de cómo las estrategias de fidelización inciden en la sostenibilidad financiera de las plataformas. En particular, la aplicación de modelos predictivos para medir el impacto económico de la retención de clientes representa un campo aún poco explorado, pero con un gran potencial para optimizar la rentabilidad de este sector.

Si bien la optimización de costes y la eficiencia operativa son elementos clave para la sostenibilidad de las plataformas de *food delivery*, por sí solos no garantizan su rentabilidad a largo plazo. La relación con los clientes y su retención adquieren un papel crucial en este equilibrio, ya que una base de usuarios recurrentes permite reducir los costes de adquisición y aumentar la estabilidad financiera del negocio. En este sentido, las estrategias de fidelización han cobrado relevancia como una herramienta para reforzar la lealtad del cliente y mejorar los ingresos sostenibles. La siguiente sección analiza en detalle los programas de retención y recompensas, evaluando su impacto en la satisfacción del cliente y su contribución a la rentabilidad de las plataformas.

2.5. Estrategias de retención y programas de recompensas

En un mercado altamente competitivo, la fidelización de los clientes en plataformas de *delivery* digital se ha convertido en un desafío estratégico clave. Para abordar este reto, las plataformas han desarrollado programas de fidelización que buscan mejorar la satisfacción del cliente y reforzar su lealtad a largo plazo. Yuan y Lai (2023) identifican seis pilares fundamentales en la construcción de la lealtad del consumidor en este contexto: credibilidad de marca, compromiso de marca, satisfacción del cliente, valor percibido, involucramiento con la marca y actitud del consumidor.

Para maximizar la fidelización, investigadores como Limsarun et al. (2021) señalan que las empresas de *food delivery* no deberían limitarse a estrategias de corto plazo, sino también desarrollar iniciativas sostenibles a largo plazo. Entre sus recomendaciones destaca la creación de comunidades digitales en redes sociales como Instagram, X (anteriormente Twitter) y TikTok, que pueden fomentar la satisfacción del cliente a través de una mayor interacción y contenido relevante. Asimismo, subrayan la importancia del *big data* como herramienta clave para predecir el comportamiento de compra y optimizar las estrategias de fidelización.

Desde otra perspectiva, Kovalev et al. (2022), subrayan la necesidad de que las pequeñas empresas de restauración, con recursos más limitados, adopten sistemas de gestión de relaciones con clientes (CRM) como apoyo para sus programas de fidelización. Este tipo de tecnología permite personalizar la experiencia del usuario y aprovechar al máximo los recursos disponibles, facilitando su competitividad frente a las grandes cadenas.

En el caso de los servicios de comida saludable y *delivery*, Bawornmongkolsak (2021) destaca que el precio es un factor determinante para los consumidores. Su análisis concluye que ofrecer productos asequibles y complementarlos con promociones específicas es crucial para atraer y retener clientes. Además, resalta el papel de blogueros y líderes de opinión, cuyas reseñas tienen un impacto significativo en la percepción de los consumidores y en sus decisiones de compra.

Por otro lado, Panjaitan (2021) argumenta que los descuentos agresivos, como *cashback*, envíos gratuitos y reducciones en los precios, son los principales impulsores de la satisfacción del cliente y, por ende, de la fidelización. No obstante, advierte que un exceso de promociones puede generar confusión entre los usuarios, dificultando su familiarización con los programas de fidelización, como observó en su estudio sobre la plataforma Lazada.

Si bien los programas de fidelización han demostrado ser herramientas clave para mejorar la satisfacción del cliente y reforzar su lealtad, su impacto en la rentabilidad de las plataformas de *food delivery* aún plantea interrogantes. Más allá de las estrategias de retención, es necesario evaluar en qué medida estas iniciativas contribuyen a la sostenibilidad económica del negocio. La siguiente sección analiza la relación entre fidelización y rentabilidad, explorando los factores que determinan la viabilidad financiera de estas plataformas y su capacidad para equilibrar la retención de clientes con el rendimiento económico.

2.6. Relación entre fidelización y rentabilidad

La rentabilidad de las plataformas de *food delivery* depende en gran medida de su capacidad para fidelizar clientes, ya que la retención de usuarios reduce los costes de adquisición

y aumenta el valor del ciclo de vida del cliente (*Customer Lifetime Value*, en inglés; CLV, por sus siglas) (Delgado, 2023). La literatura ha identificado varios factores que influyen en la fidelización dentro de este sector, incluyendo la calidad del servicio, la satisfacción del cliente, la confianza y las estrategias de marketing personalizadas (Siddiqi et al., 2024).

Entre estos factores, la satisfacción del cliente se destaca como uno de los principales impulsores de la fidelización, pues media entre la calidad del servicio y la lealtad del usuario. Investigaciones previas muestran que los clientes satisfechos tienen una mayor intención de recompra y suelen recomendar la plataforma, contribuyendo a reducir la pérdida de cliente y a incrementar el CLV (Siddiqi et al., 2024). Además, el nivel de confianza en la marca de la plataforma de *delivery* también juega un papel clave en la intención de recompra, ya que los consumidores tienden a mantener su lealtad cuando perciben que la empresa es confiable y responde adecuadamente a problemas del servicio (Sharma et al., 2023).

Asimismo, la percepción del precio y la propuesta de valor resultan determinantes en la fidelización del consumidor (Sharma et al., 2023). Aunque los usuarios son sensibles al precio, también valoran la conveniencia, la calidad del servicio y la fiabilidad de la entrega. En este sentido, incluso si los precios son elevados, los consumidores suelen mostrarse dispuestos a pagar más cuando perciben un valor agregado, especialmente en términos de calidad y confianza en la plataforma (Sharma et al., 2023).

Las estrategias de marketing basadas en datos constituyen otra herramienta clave para reforzar la relación con el cliente y optimizar los recursos destinados a campañas de fidelización (Kumar & Petersen, 2005). Particularmente, los modelos predictivos de CLV permiten a las plataformas distribuir incentivos de forma más efectiva, dirigiéndolos a usuarios con mayor potencial de generar ingresos sostenibles. Métricas como la frecuencia de compra, el valor promedio del pedido y la tasa de retención de clientes cobran especial relevancia para diseñar estas estrategias (Delgado, 2023). No obstante, conviene matizar que el uso excesivo de descuentos y promociones puede derivar en una retención meramente temporal y no garantizar lealtad a largo plazo, afectando de forma negativa la rentabilidad si no se gestiona adecuadamente (Sharma et al., 2023).

Cabe destacar que la eficiencia operativa y logística también influye en la experiencia del cliente y, por ende, en su retención. Leuschner et al. (2012) señalan que un desempeño logístico sólido, medido por la puntualidad en las entregas, la exactitud de los pedidos y la comunicación efectiva, contribuye a la satisfacción del usuario. Aun así, implementar y mantener sistemas logísticos avanzados puede implicar costes considerables, por lo que su efecto en la rentabilidad no siempre es inmediato (Sharma et al., 2023). Este aspecto ya se ha abordado en mayor detalle

en la sección 2.4, dedicada a la rentabilidad y modelos de negocio, pero resulta pertinente reiterar aquí su relevancia para la fidelización.

Si bien la literatura ha explorado ampliamente la relación entre fidelización y rentabilidad en las plataformas de *food delivery*, persisten interrogantes sobre los mecanismos exactos que determinan su impacto financiero. A pesar de los avances en modelos de marketing basados en datos y estrategias de retención, aún falta una evaluación integral de su efecto en métricas clave como el CLV y la sostenibilidad a largo plazo. La siguiente sección identifica los principales vacíos en la investigación, destacando la necesidad de enfoques más precisos que permitan cuantificar la influencia de la fidelización en la rentabilidad y la estabilidad financiera de estas plataformas.

2.7. Gaps en la literatura

A pesar del creciente número de estudios sobre el impacto de la digitalización y las estrategias de fidelización en el sector del *food delivery*, la literatura aún presenta vacíos significativos en el análisis de su relación con la rentabilidad empresarial.

Por un lado, Scarlat et al. (2022), Amankwah-Amoah et al. (2021) y Härmand (2021) han analizado cómo la pandemia aceleró la digitalización y promovió la adopción de plataformas de *food delivery*, facilitando su crecimiento y la optimización de procesos. Sin embargo, estos estudios no profundizan en cómo esta digitalización afecta específicamente la estructura de costes y la rentabilidad de las plataformas a largo plazo.

Asimismo, Van Veldhoven et al. (2021) evaluaron el impacto financiero de plataformas como Deliveroo en los restaurantes, concluyendo que, aunque mejoran la liquidez, sus efectos sobre la rentabilidad no son concluyentes. No obstante, el estudio no examina el impacto directo en la rentabilidad de las propias plataformas de *delivery* ni cómo estas podrían optimizar sus modelos de negocio para garantizar una sostenibilidad financiera estable.

En cuanto a la fidelización, Donsuchit & Nuangjamnong (2022), Renaldi et al. (2024) y Zhang & Ha (2024) han explorado la influencia de la satisfacción del cliente y la calidad del servicio en la retención de usuarios. Sin embargo, estos trabajos no establecen una conexión clara entre las estrategias de fidelización y su impacto financiero, dejando sin respuesta preguntas clave sobre la rentabilidad de estos programas en un mercado altamente competitivo.

Además, Alvarez-Palau et al. (2022) señalan que muchas plataformas de *delivery* operan con márgenes ajustados e incluso con pérdidas, sosteniéndose gracias al capital de riesgo. Sin embargo, su estudio no determina si las estrategias de fidelización podrían fortalecer la sostenibilidad económica de estas plataformas o, por el contrario, generar costes excesivos sin un

retorno claro en términos de rentabilidad. Asimismo, la literatura carece de herramientas analíticas y modelos predictivos capaces de cuantificar con precisión estos efectos y de anticipar el impacto financiero de diversas estrategias de fidelización, lo que dificulta una toma de decisiones informada para la sostenibilidad de las plataformas.

Aunque Sharma et al. (2023) han explorado cómo el marketing basado en datos puede optimizar estrategias de fidelización, todavía falta un modelo integral que valore el efecto directo de la fidelización sobre métricas de rentabilidad clave, como el Customer Lifetime Value (CLV), la tasa de conversión de clientes recurrentes o el retorno de inversión (ROI) en campañas de fidelización.

Por otro lado, si bien la literatura ha analizado la relación entre satisfacción del cliente y fidelización, aún no se ha estudiado en profundidad cómo factores operativos y financieros específicos condicionan la rentabilidad de las plataformas de *food delivery*. Siddiqi et al. (2024) exploran los determinantes de la lealtad del cliente —percepción del precio, calidad del servicio y eficiencia del pago— pero no vinculan estos elementos con métricas transaccionales concretas como el valor del pedido (*Order Value*); las tarifas de procesamiento (*Payment Processing Fee*), que constituyen un costo para la plataforma; las comisiones (*Commission Fee*), cobradas a los restaurantes; las tarifas de entrega (*Delivery Fee*) o los descuentos (*Discounts and Offers*). Tampoco analizan cómo la combinación de estos factores impacta en la ganancia neta (*Profit*) y en la sostenibilidad financiera de la plataforma.

Este vacío en la literatura subraya la necesidad de evaluar la rentabilidad de las estrategias de fidelización no solo desde la conducta del consumidor, sino también desde una perspectiva financiera. A diferencia de estudios anteriores, mayoritariamente enfocados en la percepción del cliente y la calidad del servicio, este trabajo adopta un enfoque mixto que combina entrevistas con expertos de la industria y un análisis cuantitativo a partir de datos transaccionales, utilizando modelos predictivos para determinar el impacto económico real de las estrategias de fidelización en las plataformas de *food delivery*.

Esta aproximación mixta permite comprender el fenómeno de manera más integral, al abordar tanto la visión de los actores clave del sector como la evidencia estadística, cubriendo así un vacío existente en la literatura sobre la sostenibilidad financiera de las plataformas en relación con sus estrategias de fidelización y retención de clientes.

2.8. Resumen de la revisión de la literatura

Para complementar el análisis realizado en los apartados anteriores, se presenta a continuación un resumen de los principales estudios revisados en la literatura. Estas tablas

sintetizan los hallazgos clave, los métodos empleados y las conclusiones más relevantes, facilitando la comparación entre los diferentes enfoques y permitiendo identificar vacíos en la investigación existente.

Esta sistematización en la Tabla 2 permite observar de manera estructurada qué aspectos han sido más estudiados dentro del ámbito del *food delivery* y qué áreas requieren mayor exploración. En particular, se evidencia que, si bien numerosos estudios han abordado la satisfacción del cliente y la fidelización, pocos han explorado su impacto directo en la rentabilidad empresarial y la sostenibilidad financiera de estas plataformas.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Autor (es), año	País del estudio	Tipo de estudio	Objetivos	Tamaño de la población	Tipo de métrica	Hallazgos fundamentales
Addai et al., 2024	EE.UU., Portugal, Cabo Verde, India, Ghana	Modelización matemática y simulación numérica	Desarrollar y analizar un modelo matemático determinista para evaluar el impacto de las plataformas de entrega de comida online en la propagación de enfermedades transmitidas por alimentos. Examina la efectividad de las intervenciones gubernamentales en la mitigación del riesgo.	No aplica (modelo teórico con simulaciones)	Cálculo del número de reproducción básica (R_0) para evaluar el riesgo epidemiológico mediante simulación numérica con Matlab.	Los servicios de entrega de comida pueden facilitar la propagación de enfermedades alimentarias si no hay regulación y supervisión en la entrega. La sustitución fraudulenta de productos y la falta de control sanitario en repartidores aumentan el riesgo. La intervención gubernamental, a través de regulaciones e inspecciones, puede reducir significativamente la propagación de enfermedades.
Alvarez-Palau et al., 2022	España	Empírico, basado en simulaciones y datos económicos	Analizar la rentabilidad económica de las plataformas de entrega de alimentos en Barcelona y evaluar los factores que afectan su sostenibilidad financiera.	Datos de Glovo, Just Eat y Deliveroo en Barcelona	Simulación de Monte Carlo y regresión múltiple	Se estima que se necesitan entre 8,000 y 19,000 pedidos diarios para alcanzar rentabilidad. Las plataformas dependen del capital de riesgo y estrategias como "ghost kitchens" para mejorar la viabilidad económica. La dependencia de altas comisiones a restaurantes es un factor crítico en su modelo de negocio.
Amankwah-Ansoah et al., 2021	Canadá, Reino Unido, Finlandia, EE.UU	Conceptual y analítico	Examinar cómo la pandemia de COVID-19 ha acelerado la digitalización en los negocios y qué fuerzas impulsan o frenan este proceso.	No aplica (análisis de la literatura previa)	Análisis cualitativo y revisión de literatura	La pandemia de COVID-19 ha sido un gran acelerador de la digitalización, impulsando la adopción de tecnologías emergentes, pero también enfrentando barreras como intereses externos, resistencia organizacional y preocupaciones sobre la privacidad.
Arlı et al., 2024	Australia, EE.UU	Análisis sobre la influencia del modelo SERVQUAL en la satisfacción y lealtad del consumidor	Evaluar la relación entre la calidad de servicio, satisfacción y lealtad en plataformas de entrega.	Encuestas a 475 usuarios de plataformas de entrega de comida, analizadas con PLS-SEM	Síntesis teórica de estudios sobre la relación SERVQUAL-satisfacción	La calidad del servicio en plataformas de entrega de comida influye en la satisfacción y lealtad del cliente. Las dimensiones más importantes son confiabilidad, seguridad, empatía y tangibilidad, mientras que la capacidad de respuesta no tuvo un impacto significativo. Los clientes muestran mayor lealtad hacia los restaurantes que hacia las plataformas de entrega.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Bavommongkolsak, 2021	Tailandia	Mixto	Investigar los factores que afectan la lealtad del consumidor en los servicios de entrega de comida saludable en Tailandia. Analizar barreras y oportunidades para aumentar la retención de clientes en este nicho de mercado.	15 entrevistas en profundidad. 258 encuestados (usuarios de plataformas de entrega de comida)	Análisis de regresión con SPSS. Encuestas con escala Likert. Análisis de correlación de factores clave	La lealtad del cliente en la comida saludable por delivery depende de la calidad de los ingredientes, el sabor, el empaquetado, el servicio y la transparencia nutricional. Sin embargo, las principales barreras incluyen precios altos, costos de envío elevados, falta de variedad en plataformas, preferencia por tiendas físicas y ausencia de marcas consolidadas en el mercado.
Chen et al., 2022	China, Canadá, Hong Kong	Modelado teórico y análisis económico	Evaluar si las plataformas de entrega de comida beneficiarían o perjudicarían a los restaurantes.	Modelo teórico basado en datos de comportamiento de clientes	Modelado matemático de colas y teoría de juegos	Las plataformas de entrega pueden redistribuir la demanda en lugar de aumentarla, afectando la rentabilidad de los restaurantes según su base de clientes. En algunos casos, la dependencia de estas plataformas lleva a que los restaurantes operen solo como 'ghost kitchens', lo que puede afectar tanto su rentabilidad como la de la plataforma. Se sugiere un modelo de revenue-sharing para equilibrar los beneficios entre ambas partes.
Delgado, 2023	Estados Unidos	Tesis de maestría	Desarrollar un modelo de predicción del valor del ciclo de vida del cliente (CLV) en la empresa CookUnity para mejorar la retención y el rendimiento del negocio.	Datos históricos de clientes de CookUnity	Modelos de aprendizaje automático (Random Forest, XGBoost, LightGBM, Redes Neuronales). Evaluación de precisión del modelo (RMSE, validación cruzada)	CookUnity ha crecido principalmente por adquisición de clientes, sin un incremento notable en el gasto individual. El modelo predictivo de CLV permite identificar segmentos de clientes con mayor valor y riesgo de abandono, optimizando estrategias de retención. La personalización y la gestión eficiente del marketing son claves para mejorar la rentabilidad sin aumentar el presupuesto de adquisición.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Donsuchit & Nuangjamrong, 2022	Tailandia	Cuantitativo	Investigar la influencia de la calidad del servicio electrónico (E-service quality), el valor percibido y la satisfacción del cliente en la lealtad del cliente, y cómo esta lealtad impacta en la intención de recompra en aplicaciones de entrega de alimentos.	385 usuarios de aplicaciones de entrega de comida en Bangkok	Encuestas con escala Likert de 5 puntos	La calidad del servicio electrónico tiene un fuerte impacto en el valor percibido y la satisfacción del cliente. Estas variables, junto con la calidad del servicio, influyen en la lealtad del cliente, lo que a su vez afecta significativamente la intención de recompra. Se recomienda mejorar la calidad del servicio digital para fortalecer la fidelización de clientes en aplicaciones de entrega de comida.
Feldman et al., 2023	Estados Unidos	Teórico-analítico	Examinar la relación entre restaurantes y plataformas de entrega, identificando conflictos, modelos de contrato y coordinación para maximizar rentabilidad.	No aplica (modelo teórico de sistemas congestionados)	Modelos de optimización y análisis de contratos	Las plataformas de entrega generan valor para los restaurantes, pero las comisiones elevadas (15%-30%) reducen sus márgenes de ganancia. El modelo actual de comisión no optimiza el sistema y provoca precios subóptimos. Se ha propuesto un contrato híbrido con un pago fijo + porcentaje de ingresos como una solución para mejorar la coordinación y rentabilidad de los restaurantes.
Garay Freire & Álvarez Reyes, 2024	España	Revisión bibliográfica y exploratorio	Analizar el impacto de la Industria 4.0 en la logística, identificando tendencias, enfoques exitosos y desafíos en la integración de tecnologías digitales en la cadena de suministro.	Muestra diversa de empresas del sector logístico	Encuestas y análisis de datos sobre la integración de Industria 4.0	La implementación de tecnologías de la Industria 4.0 mejora la eficiencia operativa, la toma de decisiones y la expansión de mercados. Se destaca la necesidad de estrategias digitales para aumentar la competitividad y sostenibilidad de las empresas.
Hajder et al., 2023	Polonia	Análisis teórico y datos secundarios	Analizar la relación entre la digitalización, la Industria 4.0 y la pandemia de COVID-19, evaluando su impacto en la economía y el mercado laboral.	No aplica (análisis teórico)	Indicadores económicos, inversión en I+D, gasto en innovación	La pandemia aceleró la transformación digital y la adopción de Industria 4.0 en Polonia. Sin embargo, el país sigue rezagado en inversión en I+D (1% del PIB) en comparación con la media de la UE (2.1%). Se recomienda fortalecer la cooperación entre universidades, empresas y el sector público para mejorar la competitividad y fomentar la innovación.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Härmand, 2021	Estonia, Italia, Alemania, Polonia, Austria	Cualitativo	Examinar cómo los países modificaron su legislación para permitir la digitalización de reuniones anuales generales (AGM) y procesos corporativos antes y después del COVID-19	Se analizan múltiples países de la UE (Estonia, Italia, Alemania, Polonia, Austria y Suecia)	Legislación en torno a AGMs virtuales, cambios regulatorios y adopción de tecnologías digitales	La pandemia de COVID-19 ha sido un gran acelerador de la digitalización, impulsando la adopción de tecnologías emergentes mediante cambios legislativos y regulaciones temporales. Sin embargo, la implementación de estas medidas ha enfrentado barreras como preocupaciones legales sobre reuniones virtuales, privacidad de datos y desafíos técnicos en algunos países.
Hølgessen, 2000	Noruega	Empírico y cuantitativo	Investigar la relación entre satisfacción del cliente, lealtad del cliente y rentabilidad del cliente a nivel individual.	176 clientes y 564 pedidos analizados	Análisis de correlación y contabilidad de rentabilidad del cliente	La satisfacción y la lealtad del cliente están positivamente relacionadas con la rentabilidad, pero con efectos decrecientes. Se identificó un umbral de satisfacción (75%) a partir del cual el impacto en la lealtad se reduce. Se sugiere optimizar la inversión en satisfacción para maximizar la rentabilidad del cliente sin incurrir en costos innecesarios.
Islam et al., 2017	Finlandia	Modelo teórico	Desarrollar un modelo de expectativa-confirmación desglosado para evaluar la usabilidad en la continuidad del uso de tecnología.	Datos longitudinales de 125 usuarios de LinkedIn, combinados con revisión de estudios previos sobre continuidad de uso	Análisis teórico basado en modelos previos de adopción tecnológica	La usabilidad tiene un impacto más fuerte que la utilidad en la continuidad del uso de tecnología. La satisfacción del usuario es el principal predictor de la intención de continuar usando una plataforma. La confirmación de usabilidad es clave para mejorar la satisfacción del usuario, mientras que la utilidad solo influye si hay satisfacción previa.
Kovalev et al., 2023	Rusia	Análisis comparativo y modelización de programas de lealtad en el retail	Evaluar la eficiencia de los programas de lealtad en el sector minorista de alimentos, con un enfoque en tecnologías digitales y sistemas de gestión de relaciones con clientes (CRM).	Análisis de programas de lealtad en 10 minoristas de alimentos	Comparación de herramientas de fidelización (descuentos, cupones, marketing digital), índices de eficiencia de CRM y retención de clientes, y medición de tasas de uso de tarjetas de lealtad y penetración en ventas	El uso de tecnologías digitales en programas de lealtad mejora la retención y la rentabilidad. Los sistemas CRM efectivos combinan personalización con incentivos como descuentos y recompensas. Las tarjetas de lealtad se han duplicado en uso en 5 años, con una penetración del 90% en algunos minoristas. La fidelización digital basada en datos permite una segmentación más efectiva de clientes.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Kumar & Petersen, 2005	Estados Unidos	Revisión teórica y empírica	Analizar cómo una estrategia de marketing a nivel de cliente puede mejorar el rendimiento financiero de una empresa. Se propone un marco estratégico que maximiza la rentabilidad, el valor del cliente y el valor para los accionistas.	Empresas B2B y B2C estudiadas en diferentes sectores	Valor del ciclo de vida del cliente (Customer Lifetime Value, CLV), rentabilidad, equidad del cliente, valor para accionistas y estrategias de marketing basadas en datos	El éxito de una estrategia de marketing a nivel de cliente depende del uso adecuado del CLV para segmentar clientes y personalizar campañas. Se identifican siete tácticas clave para maximizar la rentabilidad y la equidad del cliente. Las empresas que implementan estrategias basadas en CLV pueden mejorar significativamente su desempeño financiero y su valor para accionistas.
Lee & Han, 2022	Corea del Sur	Cuantitativo	Identificar los antecedentes de la formación de lealtad de marca en aplicaciones de entrega de comida (Food Delivery Apps, FDAs), considerando el impacto mediador de la calidad y el valor percibido.	350 encuestados a través de encuestas en línea dirigidas a usuarios de aplicaciones de entrega en Corea del Sur	Modelado de ecuaciones estructurales (SEM)	La calidad de las FDAs influye en la lealtad de marca, con la utilidad de la información como el factor más importante. El valor percibido (especialmente el funcional) y la satisfacción de marca median esta relación. La satisfacción del cliente es el predictor más fuerte de la lealtad. Se recomienda mejorar la precisión y personalización de la información en las aplicaciones.
Leuschner et al., 2012	Estados Unidos	Cuantitativo	Examinar cómo el desempeño logístico influye en la satisfacción del cliente y en la participación en el negocio, comparando proveedores primarios y secundarios.	Muestra 1: 299 hospitales para validación inicial. Muestra 2: 753 hospitales para comparar proveedores primarios y secundarios	Modelado de ecuaciones estructurales (SEM). Comparación entre proveedores primarios y secundarios con análisis de varianza. Evaluación del impacto del Marketing Mix (producto, precio, promoción y logística) en la satisfacción del cliente	Los proveedores primarios reciben más del 75% del negocio en comparación con los secundarios. La logística es el principal factor diferenciador, destacando tiempos de entrega consistentes, manejo de reclamaciones y cumplimiento de pedidos urgentes. Para proveedores secundarios, mejorar la logística puede aumentar su cuota de negocio, mientras que para proveedores primarios, la lealtad del cliente no depende directamente de su satisfacción.
Li & Wang, 2024	EE.UU.	Análisis empírico	Evaluar el impacto de las plataformas de entrega en la demanda y ventas de los restaurantes.	Datos de restaurantes en Chicago: tráfico de clientes, transacciones bancarias y Yelp	Análisis de datos de ventas, tráfico de clientes y modelos econométricos	Las plataformas de delivery aumentan las ventas totales, pero los efectos varían: los restaurantes independientes se benefician más en el dine-in, mientras que las cadenas aumentan más en takeaway.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

LIMSARUN et al., 2021	Tailandia	Cuantitativo	Examinar los factores que afectan la lealtad del consumidor en el uso de aplicaciones de entrega de comida en Tailandia.	510 encuestados de aplicaciones de entrega de comida en Tailandia. (muestreo no probabilístico)	Modelo de ecuaciones estructurales (SEM), alfa de Cronbach para confiabilidad (0.886)	La confianza en la aplicación es el principal factor que impulsa la lealtad del consumidor en servicios de entrega de comida. La influencia social, el diseño del sistema y el ajuste tarea-tecnología también desempeñan un papel clave. El modelo TAM media la relación entre estos factores y la lealtad, demostrando que la percepción de utilidad y facilidad de uso son determinantes en la retención del usuario.
Naranjo-Armijo & Almeida-Blacio, 2024	Ecuador	Revisión bibliográfica cualitativa	Explorar la interrelación entre la transformación digital y la sostenibilidad en la gestión empresarial.	No aplica (revisión de literatura)	Análisis cualitativo y revisión de literatura	La transformación digital facilita la eficiencia operativa y la transparencia en la gestión empresarial mediante tecnologías como IA, IoT y blockchain. Sin embargo, su implementación enfrenta barreras como altos costos de inversión, resistencia organizacional y la brecha de habilidades tecnológicas.
Niu et al., 2021	China	Modelización teórica	Analizar la cooperación de los restaurantes con plataformas de entrega de comida online y comparar el impacto de la logística propia versus la logística de la plataforma en rentabilidad y sostenibilidad.	No aplica (estudio teórico basado en modelos)	Modelo de teoría de juegos y análisis de impacto ambiental (Índice de Sostenibilidad de Ventas)	La logística de la plataforma es preferida cuando el potencial del mercado online es bajo. Existen efectos opuestos entre el precio del "food & logistics" y la tasa de comisión. La estrategia de logística de la plataforma es más ecológica cuando el mercado online tiene una alta demanda. Las comisiones de las plataformas afectan significativamente la rentabilidad de los restaurantes y pueden provocar conflictos.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Panjaitan, 2021	Indonesia	Cuantitativo	Explorar el impacto de los programas de lealtad digital en la satisfacción y lealtad del cliente, utilizando Lazada como estudio de caso.	384 encuestados (usuarios de Lazada)	Modelos de regresión lineal múltiple y medición de impacto de diferentes programas de lealtad digital (puntos, cupones, newsletters, flash sales)	Los programas de lealtad digital mejoran la satisfacción y la lealtad del cliente en plataformas de comercio electrónico. Los puntos de recompensa tienen el mayor impacto en la satisfacción, mientras que los cupones electrónicos son la herramienta más efectiva para generar recompensa. La satisfacción del cliente media la relación entre los programas de lealtad y la retención. Un programa exitoso debe incluir personalización y beneficios tangibles para optimizar su efectividad.
Raj et al., 2023	Estados Unidos	Análisis empírico	Estudiar el impacto de la pandemia en los restaurantes pequeños a través de la plataforma Uber Eats.	Datos de pedidos de Uber Eats en cinco ciudades de EE.UU	Análisis de datos de pedidos, tasas de conversión y competencia	Los restaurantes pequeños que utilizaron Uber Eats durante la pandemia experimentaron un aumento significativo en la demanda, lo que contribuyó a su supervivencia a largo plazo. Los restaurantes con mayor demanda durante la crisis fueron más propensos a seguir operando un año después. Sin embargo, el aumento de la competencia en la plataforma afectó la distribución de pedidos entre restaurantes.
Renaldi et al., 2024	Indonesia	Análisis cuantitativo de encuestas y revisiones bibliográficas	Analizar los determinantes de la lealtad del cliente en aplicaciones locales de entrega de comida.	Muestra de clientes de la mayor aplicación de entrega en Indonesia	Modelos estadísticos sobre factores de lealtad en la economía compartida	El valor emocional y la percepción del precio son los principales impulsores de la lealtad del cliente en plataformas de entrega de comida. La calidad del servicio no tiene un impacto significativo en la retención de clientes. Se recomienda que las plataformas prioricen estrategias de conexión emocional y precios competitivos para mejorar la fidelización.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Ruslan et al., 2024	Malasia	Cuantitativo y correlacional	Analizar los factores clave que influyen en la satisfacción del cliente con los servicios de entrega de alimentos en UiTM Puncak Alam, Selangor, centrándose en la calidad de los alimentos, la facilidad de uso de la aplicación y el embalaje.	357 encuestados (estudiantes de UiTM Puncak Alam)	Encuesta estructurada, análisis descriptivo y correlacional mediante SPSS	La calidad del alimento, la facilidad de uso de la aplicación y el embalaje tienen un impacto significativo en la satisfacción del cliente. Factores clave como temperatura, frescura y presentación del alimento son determinantes. Se recomienda optimizar rutas de entrega, mejorar la interfaz de la app y utilizar envases térmicos para garantizar la calidad del producto.
Sahoo et al., 2024	India	Conceptual / Teórico	Proponer un sistema avanzado de entrega de alimentos mejorando eficiencia, seguridad y satisfacción del cliente.	No aplica (estudio conceptual con pruebas de prototipos)	Diseño y pruebas de entrega ergonómica y térmica	El diseño optimizado de la bolsa de entrega mejora la eficiencia del servicio, con una reducción del 50% en accidentes y un aumento en la comodidad de los repartidores. El aislamiento térmico ayuda a mantener la calidad de los alimentos, y las pruebas de satisfacción del cliente arrojaron una calificación promedio de 4.6 sobre 5.
Scariat et al., 2022	Rumania	Revisión bibliográfica y estudio de caso	Analizar el impacto de la pandemia de COVID-19 como acelerador de la digitalización en distintos sectores.	No aplica (revisión bibliográfica y casos de estudio)	Observación directa, entrevistas y análisis documental	La pandemia aceleró la digitalización en sectores como la educación y la industria editorial, destacando oportunidades estratégicas para la inversión en tecnologías digitales.
Sharma et al., 2023	Australia	Cuantitativo	Analizar la percepción de los consumidores sobre los servicios de entrega de comida post-pandemia y los factores que influyen en la lealtad digital.	347 encuestados australianos	Modelo basado en ecuaciones estructurales (SEM). Factores analizados: calidad del restaurante, calidad del servicio, precio y facilidad de uso de apps	La credibilidad del restaurante, la calidad del servicio digital y el precio son factores clave en la satisfacción del cliente. La satisfacción electrónica predice directamente la lealtad digital. La percepción del riesgo de COVID-19 modera esta relación, haciendo que los consumidores más preocupados por el contagio sean más fieles a los OFDS. Las empresas deben optimizar la experiencia digital, mejorar la confianza del usuario y reforzar la seguridad alimentaria para fortalecer la lealtad.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Shi & Shang, 2020	Internacional	Revisión teórica	Revisar cómo el modelo SERVQUAL se aplica a la evaluación de calidad en distintos sectores.	No aplica (revisión bibliográfica)	Revisión de literatura y análisis comparativo de estudios previos	El modelo SERVQUAL sigue siendo una herramienta efectiva para evaluar la calidad del servicio en diversas industrias. Ha sido adaptado en distintos sectores y comparado con SERVPERF, que mide solo la percepción sin considerar expectativas. Además, se ha combinado con otras metodologías para mejorar su precisión.
Siddiqi et al., 2024	Bangladesh	Cuantitativo	Investigar los factores que influyen en la lealtad del consumidor en los servicios de entrega de comida online, considerando la satisfacción del cliente como mediador.	300 encuestados mediante encuestas estructuradas con una escala Likert de 5 puntos	Modelado de ecuaciones estructurales (SEM). Análisis de impacto de variables como precio, calidad del servicio, facilidad de pago y eficiencia del tiempo	La calidad del servicio y la comida no garantizan la lealtad del cliente sin una experiencia global satisfactoria. Factores como precio competitivo, facilidad de pago y eficiencia en la entrega tienen un impacto mayor en la lealtad. La satisfacción del cliente media la relación entre estos factores y la fidelización. Se recomienda optimizar precios, mejorar los métodos de pago y garantizar entregas rápidas para fortalecer la retención de clientes.
Van Veldhoven et al., 2024	Bélgica	Análisis empírico	Analizar el impacto de las plataformas de entrega en el desempeño financiero de los restaurantes.	Datos financieros de 49 restaurantes belgas activos en Deliveroo (2010-2018)	Análisis de ratios financieros: rentabilidad, liquidez y solvencia	El uso de Deliveroo mejora la liquidez de los restaurantes, con un aumento del 40.4% en el Current Ratio. Sin embargo, no se encuentra un impacto significativo en la rentabilidad (ROA) y la relación con la solvencia es incierta, ya que el efecto desaparece al controlar otras variables.

Tabla 2. Comparación de fuentes y metodologías en estudios sobre food delivery

Yuan & Lai, 2023	Suecia	Cualitativo	Explorar los factores que influyen en la lealtad de marca de los consumidores en los servicios de entrega de kits de comida, con un enfoque en HelloFresh. Desarrollar un marco conceptual para comprender mejor el comportamiento del consumidor en este sector.	13 entrevistas semi-estructuradas	Análisis temático cualitativo	La lealtad de marca en los servicios de meal kits es una combinación de factores conductuales y actitudinales. Se identificaron seis factores clave que influyen en la fidelización: confianza en la marca, compromiso, satisfacción, valor percibido, involucramiento y actitud del consumidor. Las estrategias de fidelización deben abordar tanto aspectos emocionales como racionales para fortalecer la lealtad del cliente.
Zhang et al., 2024	China	Análisis empírico	Investigar cómo las plataformas de entrega de alimentos impactan la elección de alimentos saludables y la creación de entornos alimentarios digitales poco saludables.	Datos de transacciones de múltiples plataformas de entrega en China	Regresión y análisis cuasi-experimental	Las plataformas de entrega aumentan la exposición a comida poco saludable, creando “cyber food swamps”. Se observa un sesgo hacia opciones poco saludables debido a la accesibilidad y conveniencia de estos alimentos en las plataformas digitales. Las intervenciones regulatorias y el diseño de interfaces pueden influir en decisiones de compra más saludables.

A partir del análisis de los estudios incluidos en la Tabla 2, se identifican algunos sesgos relevantes que limitan la generalización de los hallazgos existentes.

En primer lugar, existe un predominio de estudios centrados en países de Asia y América del Norte, con menor representación de mercados africanos y latinoamericanos, lo que dificulta capturar la diversidad de dinámicas culturales y económicas del sector. Asimismo, desde un punto de vista metodológico, muchos trabajos se basan en encuestas o modelos teóricos sin incorporar análisis predictivos avanzados ni técnicas de *machine learning*, lo que reduce su aplicabilidad práctica para la toma de decisiones operativas.

Este vacío evidencia la necesidad de investigaciones que combinen enfoques cualitativos y cuantitativos con herramientas analíticas más robustas, tal como se propone en este estudio. El siguiente apartado expone la metodología utilizada, con el objetivo de abordar las limitaciones detectadas en la literatura previa y dar respuesta a los objetivos planteados en este estudio.

3. Metodología

La revisión de la literatura puso en evidencia los principales desafíos y estrategias relacionados con la fidelización de clientes en plataformas de *food delivery*, resaltando la necesidad de analizar su impacto en la rentabilidad. Pese a ello, aún existen brechas en la investigación cuantitativa acerca de cómo las estrategias de fidelización influyen en métricas financieras clave. Para afrontar esta limitación, el presente estudio adopta un enfoque metodológico mixto que combina análisis cualitativo y cuantitativo. A través de entrevistas con expertos y modelos predictivos basados en datos transaccionales, se busca comprender de forma integral la relación entre fidelización y rentabilidad. A continuación, se describen las etapas y técnicas aplicadas en cada vertiente metodológica.

3.1. Metodología cualitativa

3.1.1. Revisión de la literatura

Se realizó una revisión exhaustiva de literatura utilizando bases de datos académicas como Google Scholar, PubMed, Scopus y Web of Science donde se examinaron artículos científicos, informes y tesis relacionadas con la digitalización, los modelos de negocio de *food delivery*, la satisfacción del cliente y las estrategias de fidelización. Esta revisión permitió:

- Construir un marco teórico que sirviera de base para el desarrollo del trabajo.
- Identificar los factores clave en la retención de usuarios y su impacto financiero en las plataformas de *delivery*.

- Detectar vacíos en la literatura que justifican un análisis empírico más profundo sobre la relación entre fidelización y rentabilidad.

3.1.2. Entrevistas a expertos

Para complementar el análisis teórico y cuantitativo, se realizaron entrevistas semiestructuradas con profesionales del sector *food delivery* y marketing digital. Inicialmente, se contactaron a siete expertos vía LinkedIn, aunque solo dos aceptaron participar de forma anónima. Las entrevistas se llevaron a cabo mediante videollamadas en Google Meet, entre noviembre de 2024 y febrero de 2025, con una duración promedio de 15 minutos.

El objetivo fue profundizar en temas como la relevancia de los descuentos, la implementación de programas de lealtad, las comisiones aplicadas a los restaurantes y la influencia de la inteligencia artificial en la retención de usuarios. Para más detalles, consúltese el Anexo 1 (Entrevista con ex-Head of Marketing de Uber Eats) y el Anexo 2 (Entrevista con Senior Commercial Manager de Uber Eats), donde se incluye el guion de la entrevista y extractos de sus respuestas.

3.2. Metodología cuantitativa

Con el fin de evaluar de forma empírica la relación entre estrategias de fidelización (descuentos, programas de lealtad, etc.) y rentabilidad en las plataformas de *food delivery*, se aplicaron técnicas estadísticas y modelos predictivos. Concretamente, se buscó:

- Identificar patrones en el comportamiento de los usuarios.
- Estimar el impacto de variables como descuentos, comisiones y valor de pedido en la ganancia y la recurrencia.
- Generar recomendaciones basadas en datos para mejorar la sostenibilidad financiera.

3.2.1. Fuente de datos

Par realizar este estudio se ha empleado un conjunto de datos transaccionales de la plataforma Zomato, líder en el mercado indio. La selección del *dataset* se efectuó tras más de 20 horas de búsqueda en repositorios y fuentes especializadas, para asegurar representatividad y calidad. Zomato posee alrededor del 58% de la cuota de mercado, frente al 34% de Swiggy, su principal competidor. Además, Paramasivam (2024) estima que el negocio de entrega de alimentos de Zomato crecerá a un ritmo anual del 30% en los próximos cinco años, subrayando su relevancia como actor clave en el sector del *food delivery* de la India. Este liderazgo se traduce en:

- Amplio alcance geográfico y diversidad de restaurantes, reflejando un espectro significativo de la dinámica del *food delivery* en la India.
- Crecimiento constante en los últimos años, reforzando la relevancia de sus datos para entender las tendencias de fidelización y rentabilidad en este sector.

3.2.2. Métodos de análisis

El procedimiento cuantitativo se desarrolló en dos fases:

1. Análisis Exploratorio de Datos (EDA, por sus siglas en inglés): En esta fase, se identificaron valores atípicos y nulos en el conjunto de datos, además de calcularse medidas descriptivas como la media, la mediana y la desviación estándar. Asimismo, se elaboraron visualizaciones (por ejemplo, histogramas, diagramas de caja y correlaciones) para ilustrar la distribución de las variables y detectar posibles patrones relevantes.
2. Modelado Predictivo: Para evaluar la influencia de variables como *Order Value*, *Discount Rate (%)* y *Commission Rate (%)* sobre la ganancia neta (*Profit*, en inglés) y otros indicadores, se entrenaron varios algoritmos de *machine learning* (Random Forest, XGBoost, LightGBM y Redes Neuronales), aprovechando sus capacidades para capturar relaciones no lineales y comparar su rendimiento.

3.2.3. Validación y evaluación

Para garantizar la solidez y consistencia del análisis se adoptaron los siguientes procedimientos:

- Validación Cruzada: división del *dataset* en múltiples subconjuntos de entrenamiento y prueba, evaluando la estabilidad de los resultados.
- Comparación de Métricas (MAE, RMSE, R²): permitió verificar la eficacia de cada modelo para predecir *Discount Rate (%)* y *Commission Rate (%)*, así como su impacto sobre la rentabilidad.
- Explicabilidad: aplicación de técnicas como SHAP (SHapley Additive exPlanations) para comprender el peso de cada variable en las predicciones, ofreciendo claridad sobre posibles enfoques estratégicos en la toma de decisiones.

4. Análisis de Datos

El enfoque metodológico desarrollado en la sección anterior ha permitido establecer un marco sólido para analizar el impacto de las estrategias de fidelización y *pricing* en la rentabilidad de las plataformas de *food delivery*. A partir del uso de datos transaccionales y modelos

predictivos, se identificaron las variables clave que afectan la sostenibilidad del negocio. En esta sección, se lleva a cabo un análisis exhaustivo de estos datos para comprender la estructura de costes, la influencia de los descuentos y comisiones, y la relación entre los métodos de pago y la rentabilidad. Identificar estos patrones no solo permite evaluar el desempeño actual de la plataforma, sino que también proporciona una base cuantitativa para diseñar estrategias comerciales más eficientes y sostenibles.

4.1. Introducción al análisis exploratorio de datos

El Análisis Exploratorio de Datos (AED, por sus siglas en inglés) es una fase clave en el análisis de datos, que emplea técnicas estadísticas y visuales para describir y resumir su naturaleza antes de aplicar modelos predictivos. Permite detectar errores, valores atípicos y datos ausentes, además de evaluar la distribución y correlación entre variables. Su objetivo es garantizar la calidad de los datos, facilitando su preparación para análisis avanzados y asegurando que sean confiables y representativos (Ministerio de Asuntos Económicos y Transformación Digital, 2021).

4.2. Carga, limpieza y preparación de datos

Antes de realizar cualquier análisis avanzado, resulta esencial asegurar la calidad y coherencia de los datos. En esta parte, se detallan los pasos seguidos para cargar el *dataset*, tratar valores nulos, convertir divisas y generar variables temporales, con el fin de obtener un entorno confiable para el estudio.

4.2.1. Carga de datos y estructura inicial

Para iniciar el análisis, se cargó el *dataset* en un entorno de Python utilizando la librería *pandas*. Se identificaron 12 columnas con información clave sobre pedidos, clientes, restaurantes, valores monetarios y fechas, de las cuales 6 son categóricas y 6 son numéricas. Como se observa en la Ilustración 1, estas columnas se clasifican según su tipo de dato y su relevancia para el análisis posterior.

Ilustración 1. Columnas y tipos de datos del dataset

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1000 entries, 0 to 999
Data columns (total 12 columns):
#   Column                                Non-Null Count  Dtype
---  -
0   Order ID                             1000 non-null   int64
1   Customer ID                           1000 non-null   object
2   Restaurant ID                          1000 non-null   object
3   Order Date and Time                    1000 non-null   object
4   Delivery Date and Time                 1000 non-null   object
5   Order Value                            1000 non-null   int64
6   Delivery Fee                           1000 non-null   int64
7   Payment Method                         1000 non-null   object
8   Discounts and Offers                   815 non-null    object
9   Commission Fee                         1000 non-null   int64
10  Payment Processing Fee                 1000 non-null   int64
11  Refunds/Chargebacks                   1000 non-null   int64
```

Fuente: Elaboración Propia.

A continuación, se insertó una tabla con las estadísticas descriptivas de las variables numéricas (*Order Value*, *Delivery Fee*, *Commission Fee*, *Payment Processing Fee* y *Refunds/Chargebacks*), mostrando medidas como la media, la desviación estándar y los percentiles para facilitar la identificación de patrones, variaciones y posibles valores atípicos.

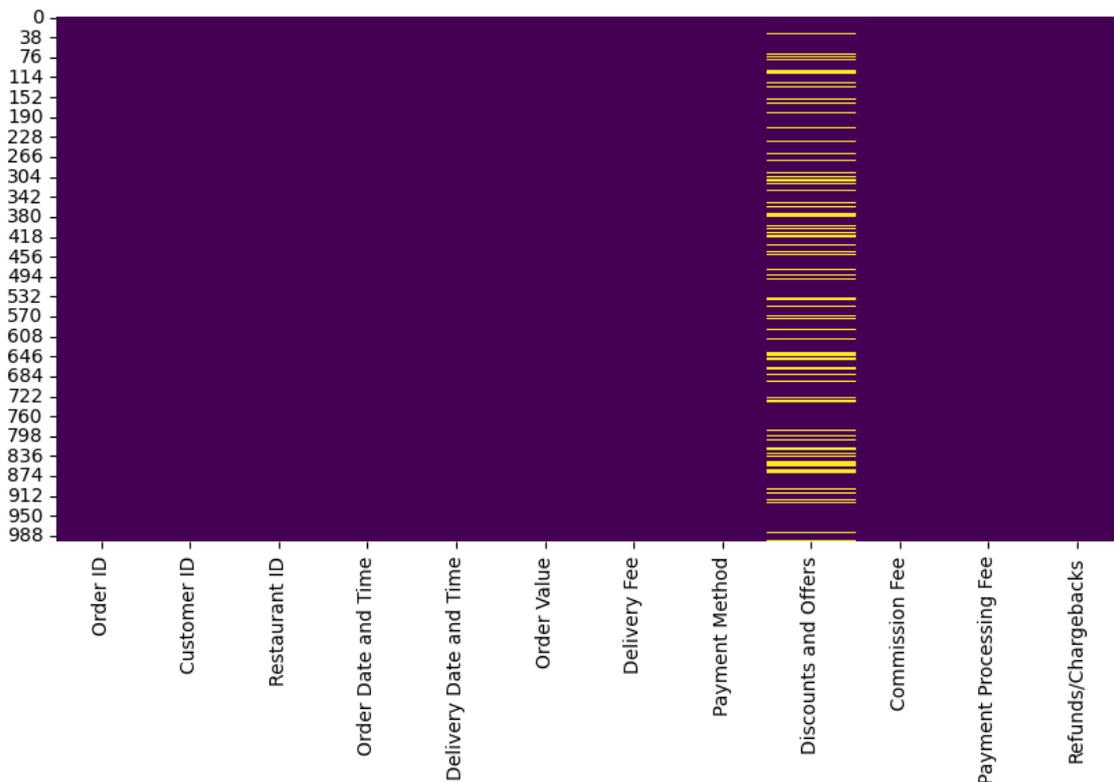
Tabla 3. *Estadísticas descriptivas de las variables numéricas*

	Order ID	Order Value	Delivery Fee	Commission Fee	Payment Processing Fee	Refunds/Chargebacks
count	1000.000000	1000.000000	1000.000000	1000.000000	1000.000000	1000.000000
mean	500.500000	1053.969000	28.620000	126.990000	29.832000	28.300000
std	288.819436	530.975339	16.958278	43.06405	11.627165	49.614228
min	1.000000	104.000000	0.000000	50.000000	10.000000	0.000000
25%	250.750000	597.750000	20.000000	90.000000	20.000000	0.000000
50%	500.500000	1038.500000	30.000000	127.000000	30.000000	0.000000
75%	750.250000	1494.000000	40.000000	164.000000	40.000000	50.000000
max	1000.000000	1995.000000	50.000000	200.000000	50.000000	150.000000

Fuente: *Elaboración Propia.*

Se realizó una inspección general para verificar la calidad de los datos. Se encontraron valores nulos en la columna *Discounts and Offers* (18.5% de valores faltantes), lo que requirió una estrategia de imputación para evitar pérdida de información. Como se observa en la Ilustración 2, se utilizó un mapa de calor para visualizar la distribución de los valores nulos en el *dataset*.

Ilustración 2. *Mapa de calor para la identificación de valores nulos en el conjunto de datos*



Fuente: *Elaboración Propia.*

Se consideró que los valores nulos correspondían a pedidos sin descuento, por lo que se sustituyeron por "0" para unificar la información de la columna.

4.2.2. Conversión de rupias indias a euros

Dado que los datos financieros estaban expresados en rupias indias (en adelante, INR), se realizó una conversión a euros (en adelante, EUR) para facilitar la interpretación económica.

Para ello, se utilizó una API de tasas de cambio en tiempo real. En caso de no disponer de conexión, el sistema aplicó una tasa de cambio predeterminada, garantizando la coherencia en el análisis financiero y reduciendo posibles sesgos en las métricas clave. Como se muestra en la Ilustración 3, este proceso permitió convertir valores expresados en rupias indias (INR) a euros (EUR) de forma automatizada.

Ilustración 3. Ejemplo de conversión de rupias indias (INR) a euros (EUR)

Tasa de cambio actual INR -> EUR: 0.0109
Conversión de moneda completada.

	Order Value	Order Value EUR
0	1914	20.86
1	986	10.75
2	937	10.21
3	1463	15.95
4	1992	21.71
5	439	4.79
6	303	3.30
7	260	2.83
8	1663	18.13
9	491	5.35

Fuente: Elaboración Propia.

4.2.3. Extracción y conversión de descuentos

En la plataforma, los descuentos pueden aplicarse en dos formatos: porcentaje (%) o cantidad fija (INR). Para garantizar la consistencia en el análisis, fue necesario estructurar esta información de manera uniforme.

En primer lugar, se estandarizó la columna de descuentos convirtiéndola a texto. Luego, se identificaron los descuentos en porcentaje extrayendo el número previo al símbolo "%", asignando un 0% si no existía un valor válido. De manera similar, para los descuentos en efectivo (INR), se eliminaron caracteres no numéricos y se identificó el primer número dentro del texto. Este proceso permitió separar correctamente los descuentos en porcentaje y en efectivo para su posterior análisis.

En la conversión de descuentos a EUR, las cantidades fijas en INR fueron transformados utilizando la tasa de cambio INR → EUR en tiempo real. Posteriormente, se calculó el descuento total en euros sumando la cantidad convertida en efectivo al valor correspondiente al descuento porcentual aplicado sobre el pedido en EUR. Esto permitió estandarizar los valores monetarios y medir con precisión el impacto financiero de las promociones en la rentabilidad de la plataforma.

Ilustración 4. *Conversión de descuentos en INR a EUR y cálculo del descuento total para estandarizar el impacto financiero en la rentabilidad de la plataforma*

Verificación de los cálculos:

	Discounts and Offers	Descuento en %	Descuento en cash
0	5% on App	5	0
1	10%	10	0
2	15% New User	15	0
3	0	0	0
4	50 off Promo	0	50
5	10%	10	0
6	5% on App	5	0
7	10%	10	0
8	5% on App	5	0
9	10%	10	0

	Descuento en cash EUR	Discount Amount EUR
0	0.00	1.04
1	0.00	1.08
2	0.00	1.53
3	0.00	0.00
4	0.55	0.55
5	0.00	0.48
6	0.00	0.16
7	0.00	0.28
8	0.00	0.91
9	0.00	0.54

Fuente: *Elaboración Propia.*

4.2.4. Conversión de costes y cálculo de rentabilidad

Para evaluar la rentabilidad de los pedidos, se convirtieron los costes de INR a EUR utilizando una tasa de cambio actualizada, incluyendo la tarifa de entrega, procesamiento de pagos y reembolsos. Luego, se calcularon los costes totales, sumando todos los gastos asociados a un pedido, incluyendo los descuentos como coste adicional. Los ingresos se definieron como la comisión cobrada a los restaurantes, y el beneficio neto se obtuvo restando los costes totales de los ingresos. Como se muestra en la Ilustración 5, este proceso permitió estandarizar el análisis económico y calcular el beneficio neto por pedido.

Ilustración 5. *Conversión de costes a EUR y cálculo del beneficio neto, considerando descuentos, comisiones e ingresos totales por pedido*

Análisis Financiero - Primeras Filas:

	Order Value	Refunds/Chargebacks	Delivery Fee	Refunds Considered EUR	Total Costs	Revenue	Profit
0	1914	0	0	0.0	1.55	1.64	0.09
1	986	0	40	0.0	1.77	2.16	0.39
2	937	0	30	0.0	2.35	2.13	-0.22
3	1463	0	50	0.0	0.84	1.59	0.75
4	1992	0	30	0.0	1.43	1.42	-0.01

Fuente: *Elaboración Propia.*

En cuanto a los reembolsos (*refunds*, en inglés), no todos representan una pérdida para la plataforma. Uber Eats, por ejemplo, solo asume el coste cuando la responsabilidad no es del restaurante, como en casos de problemas con el repartidor, mientras que en la mayoría de los errores, el coste se deduce directamente de las ganancias del establecimiento (Uber, 2025). Por su parte, Zomato, la plataforma de la cual se ha extraído el conjunto de datos para este estudio, ha comenzado a trasladar estos costes a los restaurantes desde 2023, especialmente en situaciones

de cancelaciones recurrentes o problemas de calidad, y no ofrece reembolsos automáticos por retraso, dejando estos casos a su discreción (StartupStory, 2023). Dado este contexto, en el presente análisis un *refund* solo se considera un costo cuando el importe del reembolso más la tarifa de envío supera el valor total del pedido, lo que indica que la plataforma ha asumido la pérdida en su totalidad en lugar de descontarla del restaurante. Este criterio permite evaluar de manera más realista la rentabilidad, reflejando únicamente aquellos casos en los que la empresa incurre en un coste directo.

Este enfoque impacta positivamente la rentabilidad, ya que solo un 1.05 % del total de reembolsos fue asumido por la plataforma, con un importe de 4.37 EUR frente a 309.37 EUR de reembolsos registrados. Como se observa en la Ilustración 6, la mayoría de los *refunds* son cubiertos por los restaurantes, lo que minimiza el impacto financiero sobre la plataforma.

Ilustración 6. *Análisis de reembolsos y su efecto en la rentabilidad de la plataforma*

```
Análisis de Refunds:  
Total de Refunds registrados: 285  
Importe medio de TODOS los Refunds (EUR): 1.09  
Importe total de TODOS los Refunds (EUR): 309.37  
-----  
Total de Refunds asumidos por la plataforma: 3  
Importe medio de Refunds asumidos (EUR): 1.46  
Importe total de Refunds asumidos (EUR): 4.37  
Porcentaje de Refunds asumidos: 1.05%
```

Fuente: Elaboración Propia.

4.2.5. Transformación de fechas y creación de variables temporales

Para facilitar el análisis temporal de los pedidos, se llevaron a cabo varias transformaciones. Primero, se convirtieron las columnas *Order Date and Time* y *Delivery Date and Time* al formato *datetime* de Python. Luego, se calculó la duración del pedido en minutos restando la fecha y hora de entrega a la de realización del pedido, una métrica clave para evaluar la eficiencia en la entrega.

Además, se generaron nuevas variables temporales. Se extrajo el día de la semana en que se realizó cada pedido, facilitando el análisis de patrones de consumo según el día. También se categorizó el momento del día, dividiendo las horas en *Mañana* (6:00-10:59), *Tarde* (11:00-17:59) y *Noche* (18:00-4:59). Esta clasificación se basa en los horarios típicos de comidas en la India, donde el desayuno suele tomarse entre las 7:00 y las 11:00, el almuerzo entre las 12:00 y las 15:00 y la cena entre las 19:00 y las 23:00 (Mateo, 2019; Wiki User, 2022).

Como se observa en la Ilustración 7, estas transformaciones permiten identificar tendencias en la demanda y evaluar la eficiencia logística en distintos momentos del día, proporcionando una visión detallada del comportamiento del cliente y del rendimiento operativo.

Ilustración 7. Transformaciones temporales: cálculo de duración de pedidos y categorización por día y momento del día

Primeras filas con las nuevas variables temporales:

	Order Date and Time	Delivery Date and Time	Delivery Time (min)
0	2024-02-01 01:11:52	2024-02-01 02:39:52	88.0
1	2024-02-02 22:11:04	2024-02-02 22:46:04	35.0
2	2024-01-31 05:54:35	2024-01-31 06:52:35	58.0
3	2024-01-16 22:52:49	2024-01-16 23:38:49	46.0
4	2024-01-29 01:19:30	2024-01-29 02:48:30	89.0

	Day of Week	Day Name	Time of Day
0	3	Thursday	Noche
1	4	Friday	Noche
2	2	Wednesday	Noche
3	1	Tuesday	Noche
4	0	Monday	Noche

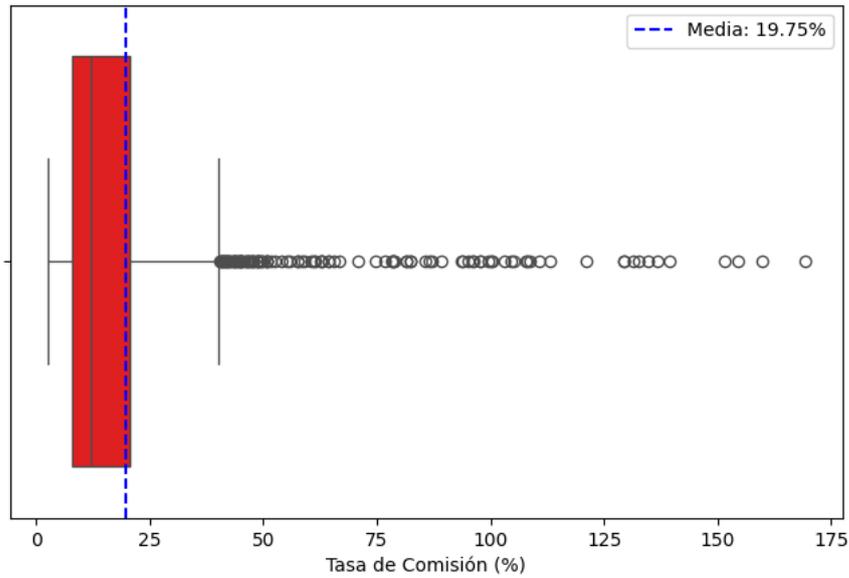
Fuente: Elaboración Propia.

4.3. Detección y Tratamiento de Valores Atípicos

El análisis de valores atípicos (*outliers*, en inglés) reveló su presencia en algunas variables, aunque su impacto no resultó significativo para los objetivos de este estudio. No obstante, en la tasa de comisión (%) cobrada a los restaurantes se detectaron valores atípicos relevantes, lo que motivó un examen detallado de su estructura y posibles patrones inusuales, dado que las comisiones influyen de forma directa en la rentabilidad.

Para detectar valores atípicos en la tasa de comisión (%), se emplearon métodos gráficos, como diagramas de caja (*boxplots*, en inglés), y enfoques estadísticos, incluyendo el análisis del rango intercuartílico. Se identificó que un 2.1% de los pedidos presentan tasas superiores al 100%, con una media del 126%, lo que sugiere que algunos restaurantes enfrentan comisiones excesivamente altas. Esto podría deberse a acuerdos específicos dentro de Zomato, cuyos planes de comisiones no son públicos. En comparación, Uber Eats y DoorDash aplican sistemas similares de comisiones escalonadas, que oscilan entre el 15% y el 30% dependiendo del nivel de visibilidad y marketing contratado (DoorDash, 2023; Uber Eats, 2025). Por otro lado, Glovo establece tarifas entre el 15% y el 43% según el tipo de entrega, además de cobrar una comisión inicial de 150€ + IVA para darse de alta en la plataforma (Food Pac, 2024). La falta de transparencia en Zomato impide una comparación directa con estos modelos y podría explicar la presencia de tasas de comisión inusualmente altas en algunos pedidos.

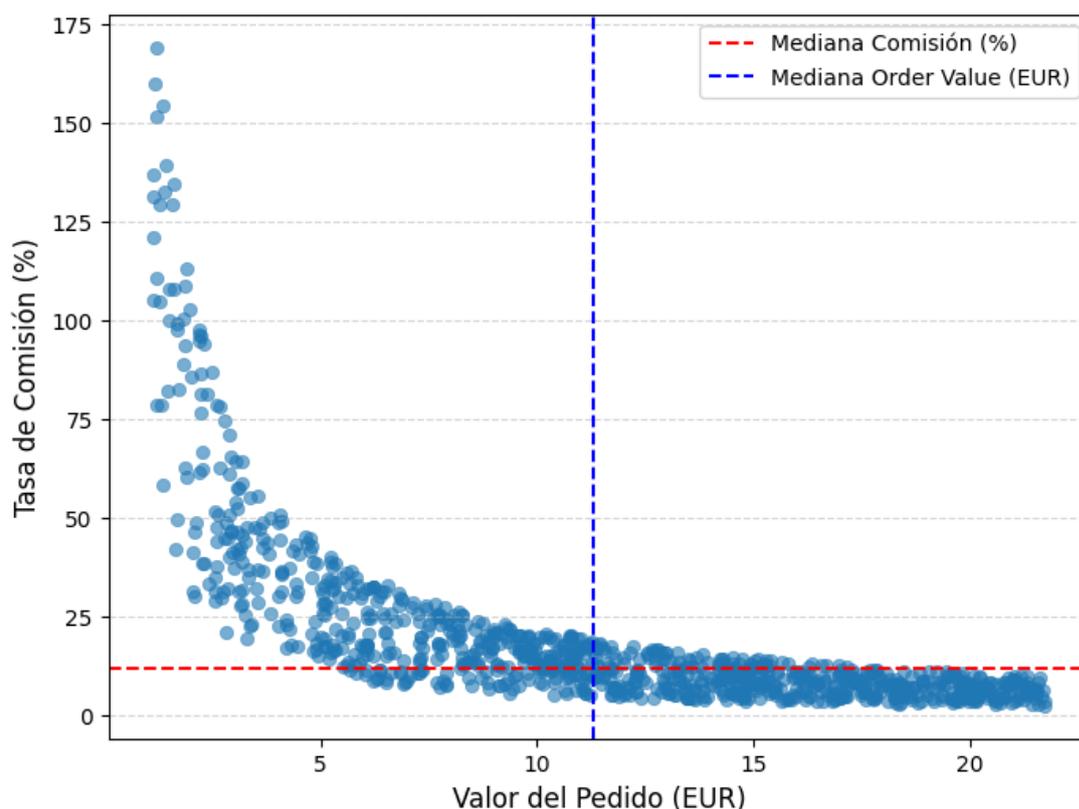
Ilustración 8. *Boxplot de la tasa de comisión (%): Identificación de valores atípicos*



Fuente: Elaboración Propia.

Los valores atípicos identificados corresponden principalmente a pedidos con comisiones superiores al 100 %, cuyo *Average Order Value* (AOV) es notablemente bajo: 1.44 EUR frente a 11.81 EUR en el resto de los pedidos. Esto sugiere que algunos restaurantes podrían estar enfrentando tarifas desproporcionadas, posiblemente derivadas de acuerdos comerciales específicos. Todo apunta a que Zomato podría aplicar un sistema de monetización que combine una tarifa fija por pedido con una comisión variable. Como se observa en la Ilustración 9, se detectó una relación inversa entre el valor del pedido y la tasa de comisión porcentual: cuanto menor es el importe, mayor es la comisión aplicada. Este patrón refuerza la idea de que el modelo actual penaliza especialmente a los pedidos de bajo valor.

Ilustración 9. Relación entre el valor del pedido y la tasa de comisión (%)



Fuente: Elaboración Propia.

Para profundizar en la estructura de comisiones de Zomato, se aplicaron diversos modelos de regresión con el objetivo de determinar si existe una combinación de tarifa fija y una comisión variable decreciente en función del valor del pedido. Este enfoque permitió contrastar cuatro variantes (lineal simple, logarítmica, polinómica e inversa) y evaluar cómo la tasa de comisión evoluciona a medida que se modifica el importe de la compra.

En primer lugar, la regresión lineal simple confirma que la tasa de comisión porcentual disminuye progresivamente a medida que aumenta el valor del pedido, con una reducción estimada del 2.64 % por cada euro adicional. Este resultado, representado en la Ilustración 10, refuerza la relación inversa identificada previamente entre ambas variables y sugiere que, aunque la comisión fija inicial es del 50.13 %, los restaurantes con pedidos de mayor importe terminan pagando una proporción significativamente menor en comisiones. Este patrón —visualizado gráficamente en la Ilustración 11— contribuye a explicar por qué los pedidos de bajo valor pueden estar especialmente penalizados, al concentrar gran parte de la carga relativa de costes.

Ecuación 1. Modelo lineal de comisión (%)

$$\text{Commission Rate} = \beta_0 + \beta_1 \times \text{Order Value}$$

Nota. β_0 (intercepto) representa la tasa de comisión estimada cuando el valor del pedido es cero, indicando una tarifa base fija para los restaurantes. β_1 (pendiente) mide cómo varía la comisión con cada euro adicional en el pedido.

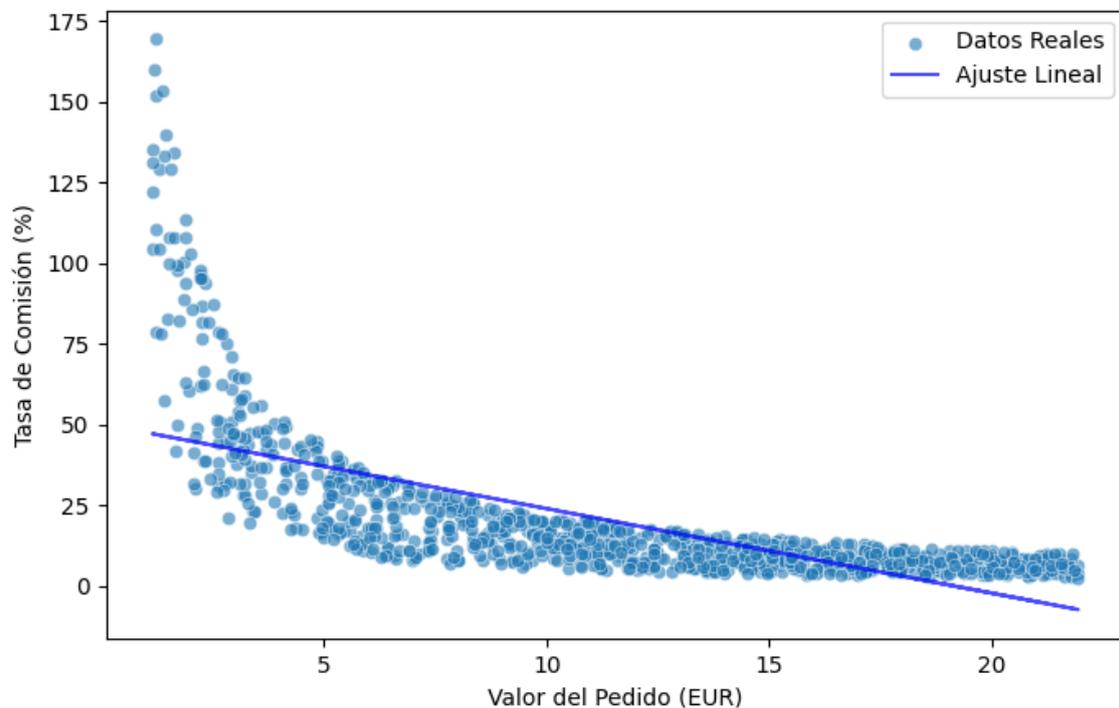
Fuente: *Elaboración Propia.*

Ilustración 10. Resultados de la regresión línea simple

OLS Regression Results						
Dep. Variable:	Commission Rate (%)	R-squared:	0.456			
Model:	OLS	Adj. R-squared:	0.456			
Method:	Least Squares	F-statistic:	837.8			
Date:	Thu, 27 Feb 2025	Prob (F-statistic):	3.10e-134			
Time:	19:38:31	Log-Likelihood:	-4234.2			
No. Observations:	1000	AIC:	8472.			
Df Residuals:	998	BIC:	8482.			
Df Model:	1					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	50.1348	1.175	42.659	0.000	47.829	52.441
Order Value EUR	-2.6447	0.091	-28.944	0.000	-2.824	-2.465
Omnibus:	685.129	Durbin-Watson:	2.045			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	9624.622			
Skew:	3.008	Prob(JB):	0.00			
Kurtosis:	16.957	Cond. No.	28.7			

Fuente: *Elaboración Propia.*

Ilustración 11. Regresión lineal: tasa de comisión (%) vs. valor del pedido



Fuente: *Elaboración Propia.*

En segundo lugar, la regresión logarítmica mostró que la tasa de comisión porcentual disminuye de manera acelerada a medida que aumenta el valor del pedido, con una comisión fija

inicial del 82.38 % y una variación negativa de -27.73 % en función del logaritmo del valor del pedido. Como se observa en la Ilustración 12, este modelo proporciona un mejor ajuste para los valores atípicos y refleja con mayor precisión el comportamiento no lineal de la variable dependiente. Además, la Ilustración 13 visualiza gráficamente esta relación, mostrando cómo los pedidos de menor importe enfrentan tasas de comisión desproporcionadamente altas, mientras que a medida que el importe aumenta, la tasa disminuye progresivamente.

Ecuación 2. Modelo logarítmico de comisión (%)

$$Commission\ Rate = \beta_0 + \beta_1 \times \ln (Order\ Value)$$

Nota. β_0 (intercepto) representa la tasa de comisión estimada cuando el valor del pedido es cero, indicando una tarifa base fija para los restaurantes. β_1 (pendiente) mide cómo varía la comisión en función del logaritmo del valor del pedido, reflejando una disminución progresiva de la tasa a medida que el importe del pedido aumenta.

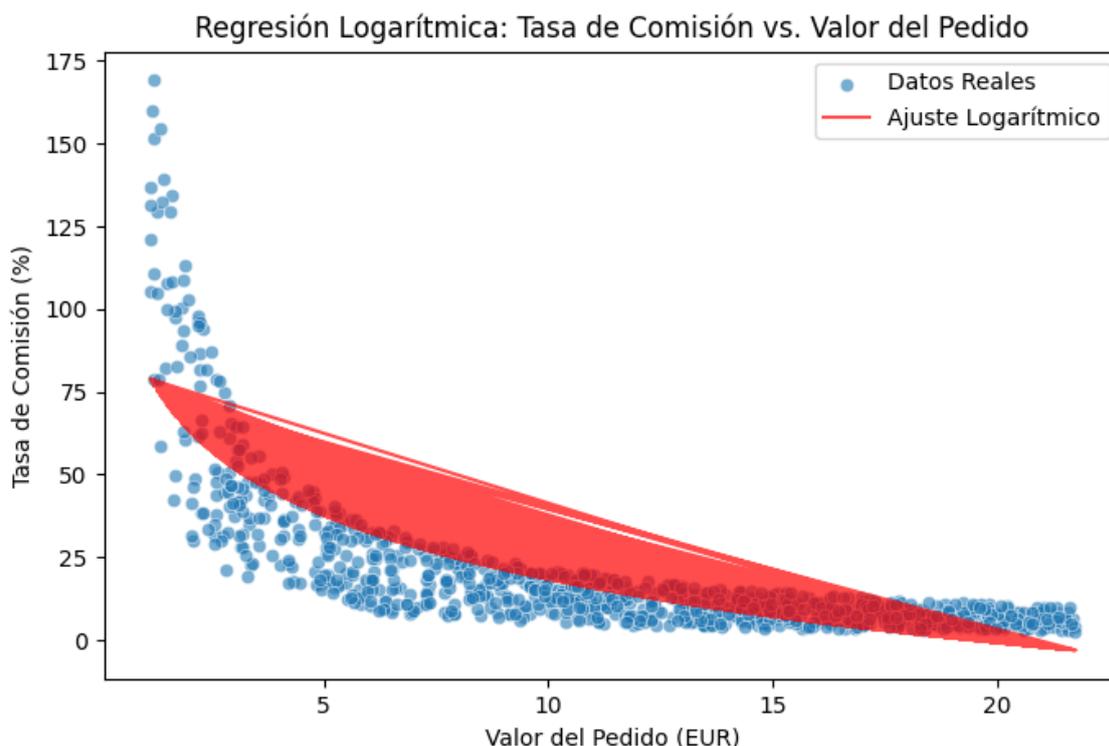
Fuente: Elaboración Propia.

Ilustración 12. Resultados de la regresión logarítmica

OLS Regression Results						
Dep. Variable:	Commission Rate (%)	R-squared:	0.697			
Model:	OLS	Adj. R-squared:	0.697			
Method:	Least Squares	F-statistic:	2295.			
Date:	Thu, 27 Feb 2025	Prob (F-statistic):	5.46e-261			
Time:	19:30:07	Log-Likelihood:	-3942.0			
No. Observations:	1000	AIC:	7888.			
Df Residuals:	998	BIC:	7898.			
Df Model:	1					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	82.3788	1.365	60.333	0.000	79.699	85.058
log_Order_Value	-27.7304	0.579	-47.911	0.000	-28.866	-26.595
Omnibus:	500.860	Durbin-Watson:	2.025			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	5820.158			
Skew:	2.009	Prob(JB):	0.00			
Kurtosis:	14.115	Cond. No.	9.52			

Fuente: Elaboración Propia.

Ilustración 13. Regresión logarítmica: tasa de comisión (%) vs. valor del pedido



Fuente: Elaboración Propia.

En tercer lugar, la regresión polinómica sugiere que la relación entre la tasa de comisión y el valor del pedido no es completamente lineal. Se identificó una comisión fija inicial del 82.85 %, acompañada de un efecto lineal negativo (-10.30 % por cada euro adicional), que se ve atenuado por un efecto cuadrático positivo (0.33 % por EUR²). Como se observa en la Ilustración 14, este modelo captura mejor la posible curvatura en la relación, indicando que, aunque la tasa de comisión disminuye a medida que el pedido aumenta, la velocidad de dicha reducción se ralentiza progresivamente. Además, la Ilustración 15 representa visualmente esta tendencia no lineal, lo que refuerza la idea de que el impacto de un pedido más elevado en la reducción de comisiones no se mantiene constante.

Ecuación 3. Modelo polinómico de comisión (%)

$$\text{Commission Rate} = \beta_0 + \beta_1 \times \text{Order Value} + \beta_2 \times \text{Order Value}^2$$

Nota. β_0 (intercepto) representa la tasa de comisión estimada cuando el valor del pedido es cero, indicando una tarifa base fija para los restaurantes. β_1 (pendiente lineal) mide cómo varía la comisión con cada euro adicional en el pedido, mientras que β_2 (coeficiente cuadrático) captura cambios no lineales, reflejando si la relación entre el valor del pedido y la tasa de comisión sigue una tendencia creciente o decreciente a medida que el pedido aumenta.

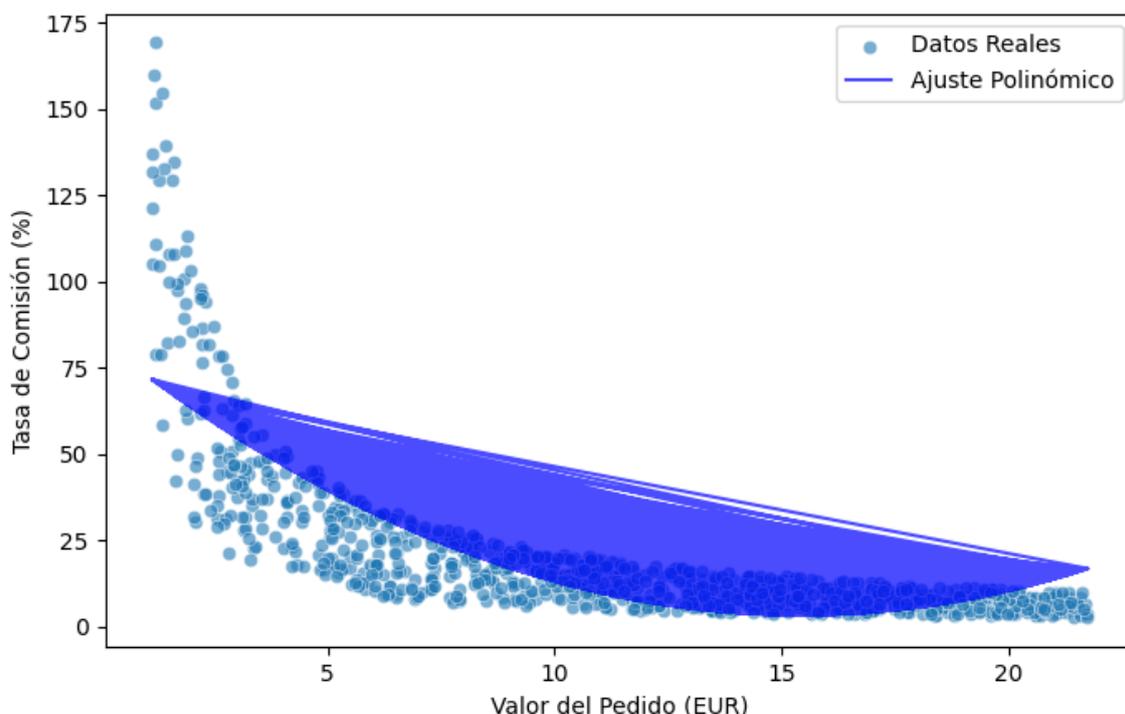
Fuente: Elaboración Propia.

Ilustración 14. Resultados de la regresión polinómica (grado 2)

OLS Regression Results						
Dep. Variable:	Commission Rate (%)	R-squared:	0.672			
Model:	OLS	Adj. R-squared:	0.672			
Method:	Least Squares	F-statistic:	1022.			
Date:	Thu, 27 Feb 2025	Prob (F-statistic):	3.49e-242			
Time:	19:32:51	Log-Likelihood:	-3981.3			
No. Observations:	1000	AIC:	7969.			
Df Residuals:	997	BIC:	7983.			
Df Model:	2					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	82.8469	1.570	52.779	0.000	79.767	85.927
Order_Value	-10.3032	0.307	-33.534	0.000	-10.906	-9.700
Order_Value_Sq	0.3341	0.013	25.620	0.000	0.308	0.360
Omnibus:	538.082	Durbin-Watson:	2.007			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	7394.667			
Skew:	2.148	Prob(JB):	0.00			
Kurtosis:	15.610	Cond. No.	834.			

Fuente: Elaboración Propia.

Ilustración 15. Regresión polinómica: tasa de comisión (%) vs. valor del pedido



Fuente: Elaboración Propia.

Por último, la regresión inversa refuerza la hipótesis de una tarifa mínima aplicada a todos los pedidos, mostrando que la tasa de comisión disminuye drásticamente a medida que aumenta el valor del pedido. El modelo estima una comisión fija cercana a -1.25 %, con un efecto inverso de 150.72 % por 1/EUR, lo que sugiere que los pedidos de menor importe soportan una carga proporcional significativamente mayor en comisiones. Como se observa en la Ilustración 16, esta relación no lineal evidencia un fuerte impacto de las tarifas fijas en pedidos de bajo valor. La Ilustración 17, por su parte, representa gráficamente esta dinámica, mostrando cómo la comisión

cae abruptamente conforme el valor del pedido crece, hasta estabilizarse en niveles cercanos a cero.

Ecuación 4. *Modelo inverso de comisión (%)*

$$Commission\ Rate = \beta_0 + \beta_1 \times \frac{1}{Order\ Value}$$

Nota. β_0 (intercepto) representa la tasa de comisión estimada cuando el valor del pedido es cero, indicando una tarifa base fija para los restaurantes. Por otro lado, β_1 (pendiente) captura el efecto inverso del valor del pedido sobre la comisión, lo que implica que los pedidos de menor cuantía enfrentan tasas de comisión proporcionalmente más altas, mientras que a medida que el pedido aumenta, la comisión disminuye de forma no lineal.

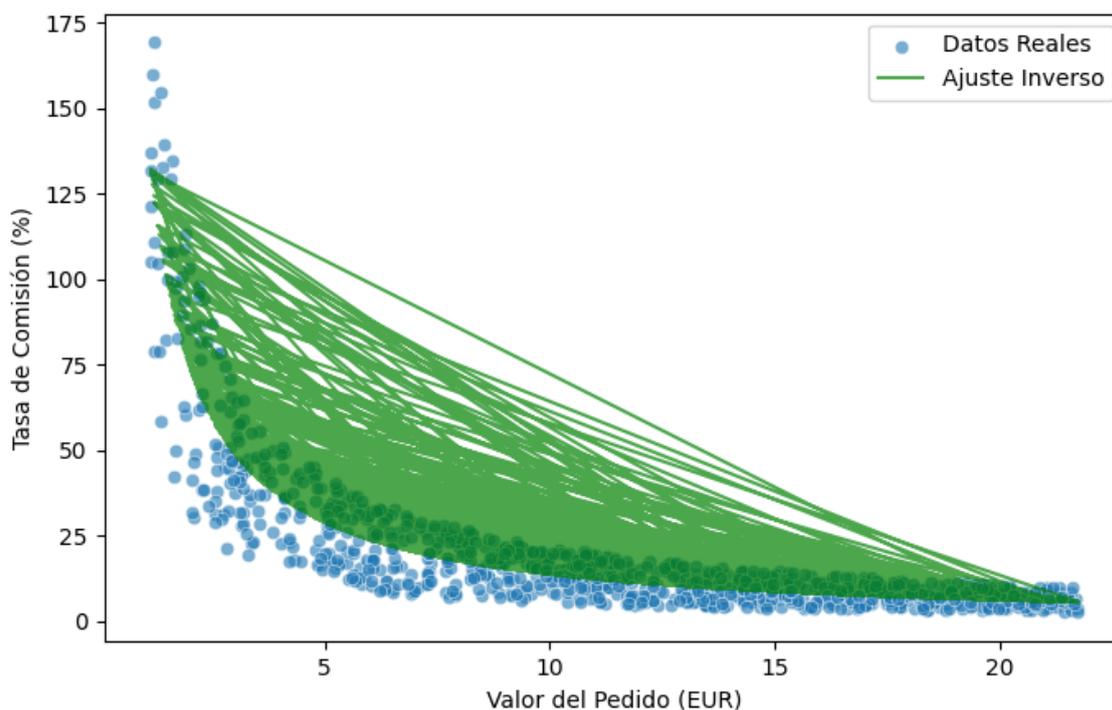
Fuente: Elaboración Propia.

Ilustración 16. *Resultados de la regresión no lineal (inversa)*

OLS Regression Results						
Dep. Variable:	Commission Rate (%)	R-squared:	0.851			
Model:	OLS	Adj. R-squared:	0.851			
Method:	Least Squares	F-statistic:	5720.			
Date:	Thu, 27 Feb 2025	Prob (F-statistic):	0.00			
Time:	19:34:11	Log-Likelihood:	-3585.6			
No. Observations:	1000	AIC:	7175.			
Df Residuals:	998	BIC:	7185.			
Df Model:	1					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	-1.2464	0.392	-3.182	0.002	-2.015	-0.478
Inv_Order_Value	150.7228	1.993	75.628	0.000	146.812	154.634
Omnibus:	164.057	Durbin-Watson:	1.989			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	2264.280			
Skew:	-0.240	Prob(JB):	0.00			
Kurtosis:	10.356	Cond. No.	7.36			

Fuente: Elaboración Propia.

Ilustración 17. Regresión no lineal inversa: tasa de comisión (%) vs. valor del pedido



Fuente: Elaboración Propia.

Estos hallazgos sugieren que Zomato podría estar utilizando un modelo de comisiones más complejo que sus competidores, combinando una tarifa fija mínima con una comisión variable en función del valor del pedido. Este enfoque explicaría por qué los pedidos de menor importe soportan tasas de comisión excepcionalmente altas, ya que la parte fija representa un porcentaje mayor sobre el total. La falta de transparencia en estos esquemas dificulta una comparación precisa con otras plataformas y resalta la necesidad de mayor claridad en la estructura de costes de los *marketplaces* de *delivery*.

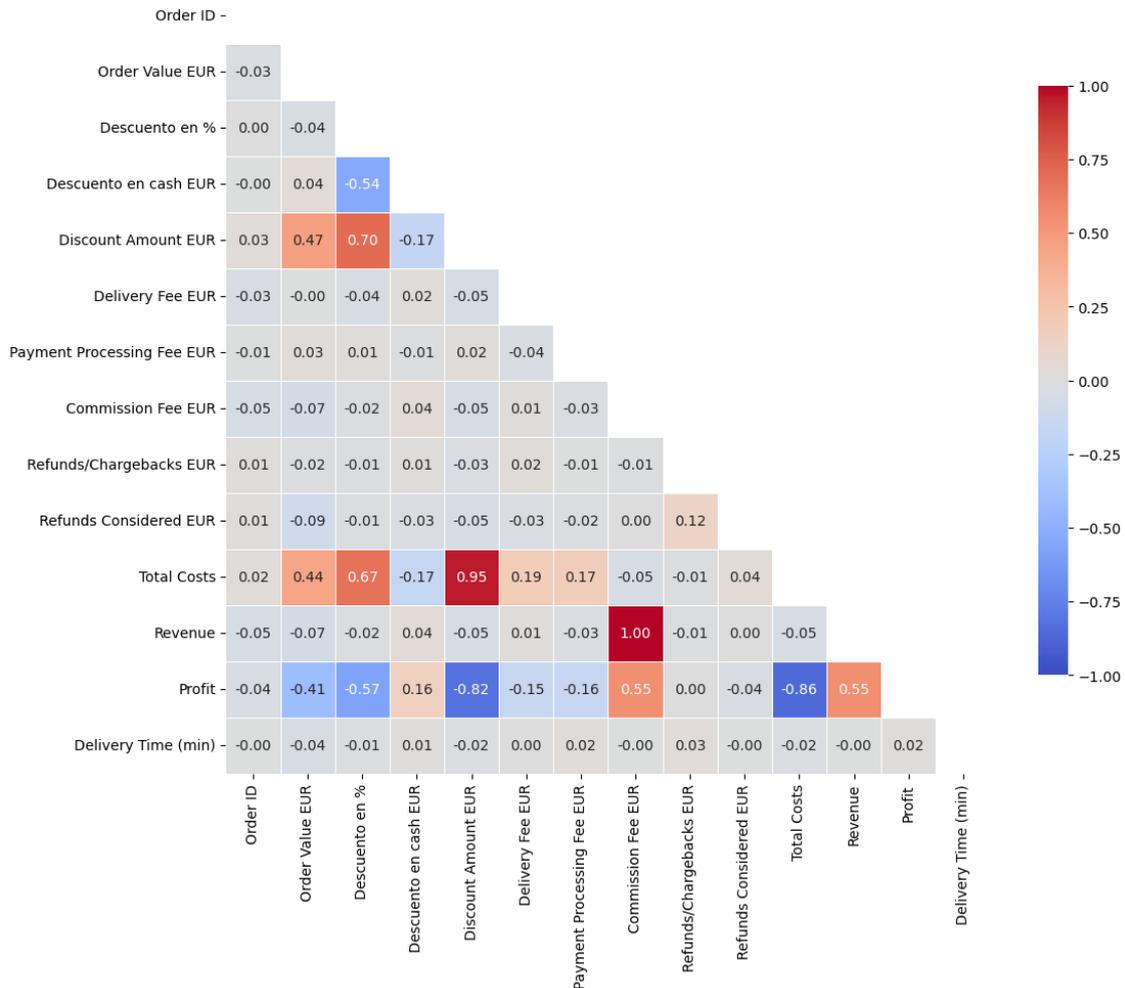
4.4. Análisis de correlación entre variables

El análisis de correlación permitió detectar relaciones significativas entre variables, revelando patrones que ayudan a explicar las variaciones en la rentabilidad. Como se muestra en la Ilustración 18, Discount Amount EUR presenta una fuerte correlación negativa (-0.82) con Profit, lo que indica que los descuentos elevados reducen de manera considerable el margen de beneficio. De forma similar, Total Costs muestra una correlación negativa de -0.86 con Profit, lo que evidencia que un aumento en los costes totales tiende a disminuir la rentabilidad de los pedidos.

Asimismo, se registra una correlación positiva +0.67 entre Discount Amount EUR y Total Costs, lo que sugiere que los descuentos más altos podrían implicar mayores costes operativos asociados. En contraste, variables como Delivery Time (min) apenas muestran relación con los

componentes financieros, evidenciando que la duración de la entrega no repercute de forma relevante en la estructura de costes ni en el beneficio final.

Ilustración 18. Mapa de calor de correlaciones (variables filtradas)



Fuente: Elaboración Propia.

4.5. Análisis descriptivo

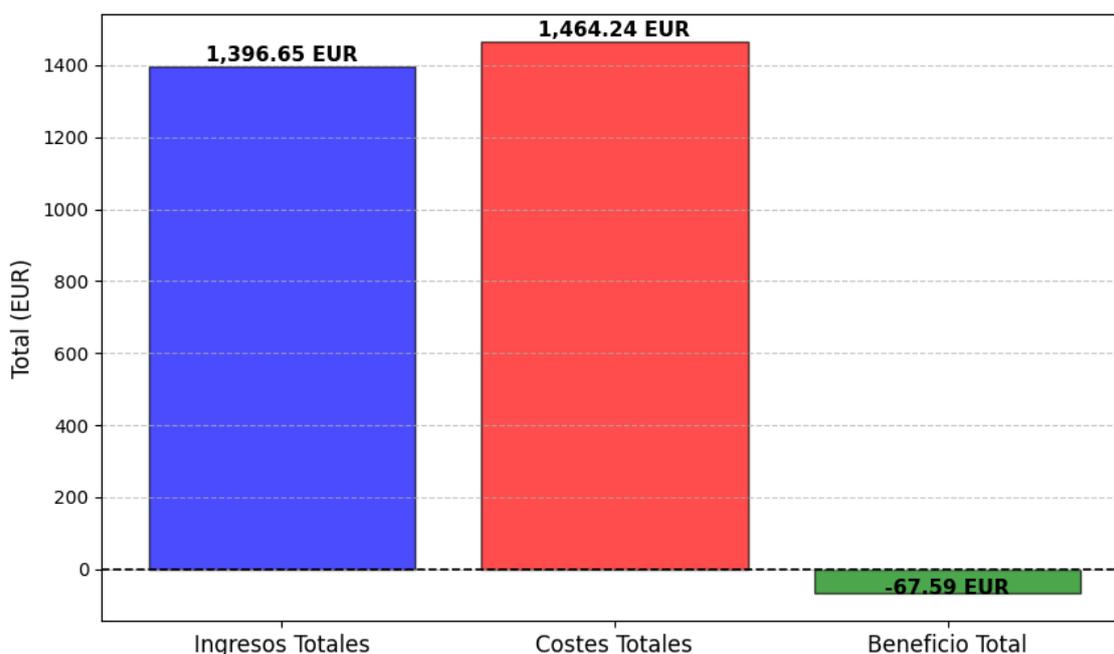
En esta sección se explora la información de manera general, describiendo el comportamiento de las variables clave y su relevancia para el modelo de negocio. El objetivo es comprender la situación financiera de los pedidos y detectar posibles tendencias que sirvan como base para análisis más profundos posteriores.

4.5.1. Estadísticas generales de los datos

El análisis descriptivo de los datos permite obtener una visión clara de la estructura financiera de los pedidos y su comportamiento en el tiempo. Para ello, se han examinado los ingresos, costes y beneficios, su evolución temporal y la distribución de diferentes factores clave, incluyendo los descuentos aplicados.

En primer lugar, la comparación entre ingresos, costes y beneficios totales pone de manifiesto un desequilibrio financiero: los costes totales (1,464.24 EUR) superan a los ingresos generados (1,396.65 EUR), lo que se traduce en una pérdida neta de -67.59 EUR. Como se observa en la Ilustración 19, este resultado sugiere que, en las condiciones actuales, la operativa no es rentable. Esta situación podría estar influenciada por diversos factores, como las estructuras de comisiones aplicadas a los restaurantes, los costes asociados a la entrega, las estrategias de descuentos empleadas o el coste de procesamiento de pagos.

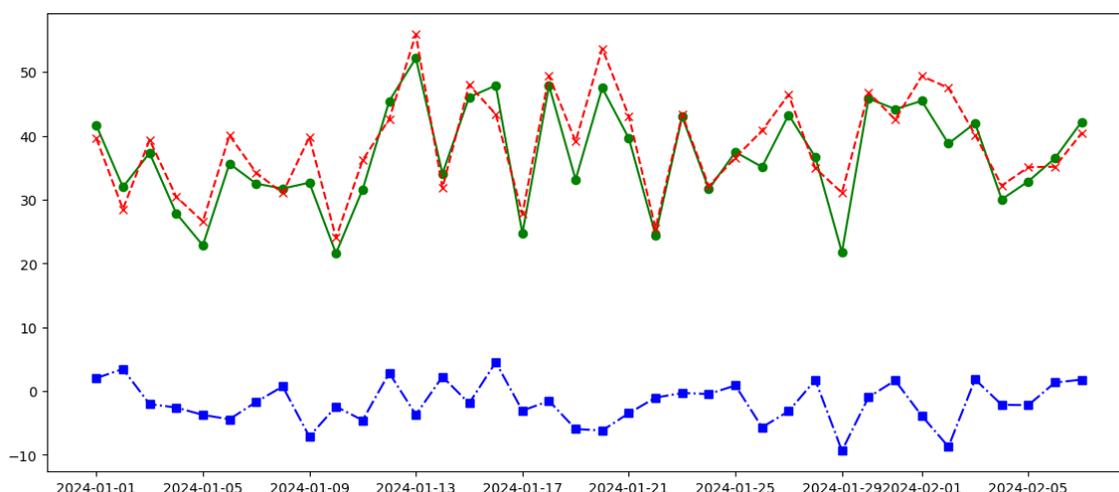
Ilustración 19. Comparación de ingresos, costes y beneficios Totales



Fuente: Elaboración Propia.

En lo que respecta a la evolución temporal de los pedidos y la rentabilidad, se aprecia una notable variabilidad en la actividad diaria. Como se muestra en la Ilustración 20, se observan picos en el volumen de pedidos que podrían coincidir con días de mayor demanda, mientras que la rentabilidad también fluctúa, alternando entre periodos de pérdidas y ganancias. Este comportamiento pone de manifiesto la importancia de analizar los patrones de consumo a lo largo del tiempo para optimizar las estrategias de precios y promociones según la demanda real.

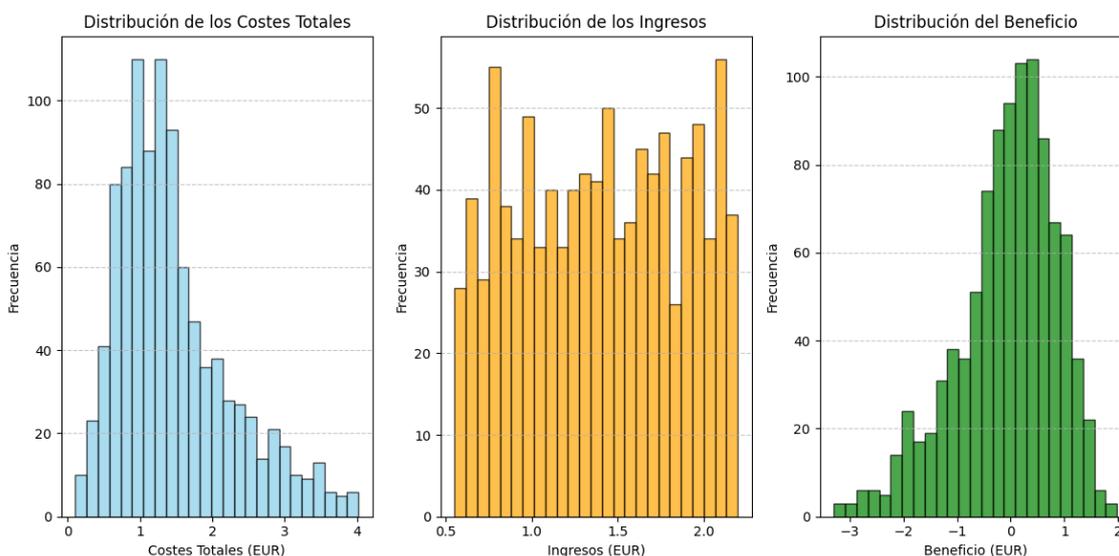
Ilustración 20. Evolución temporal de pedidos y rentabilidad



Fuente: Elaboración Propia.

Desde una perspectiva más granular, la distribución de los costes totales, ingresos y beneficios permite analizar la rentabilidad de cada pedido. Los costes suelen oscilar entre 0.5 y 3 EUR, mientras que los ingresos se concentran en valores entre 0.5 y 2 EUR. Sin embargo, la distribución del beneficio presenta una tendencia negativa en muchos casos, lo que indica que un número considerable de pedidos genera pérdidas.

Ilustración 21. Distribución de costes, ingresos y beneficio

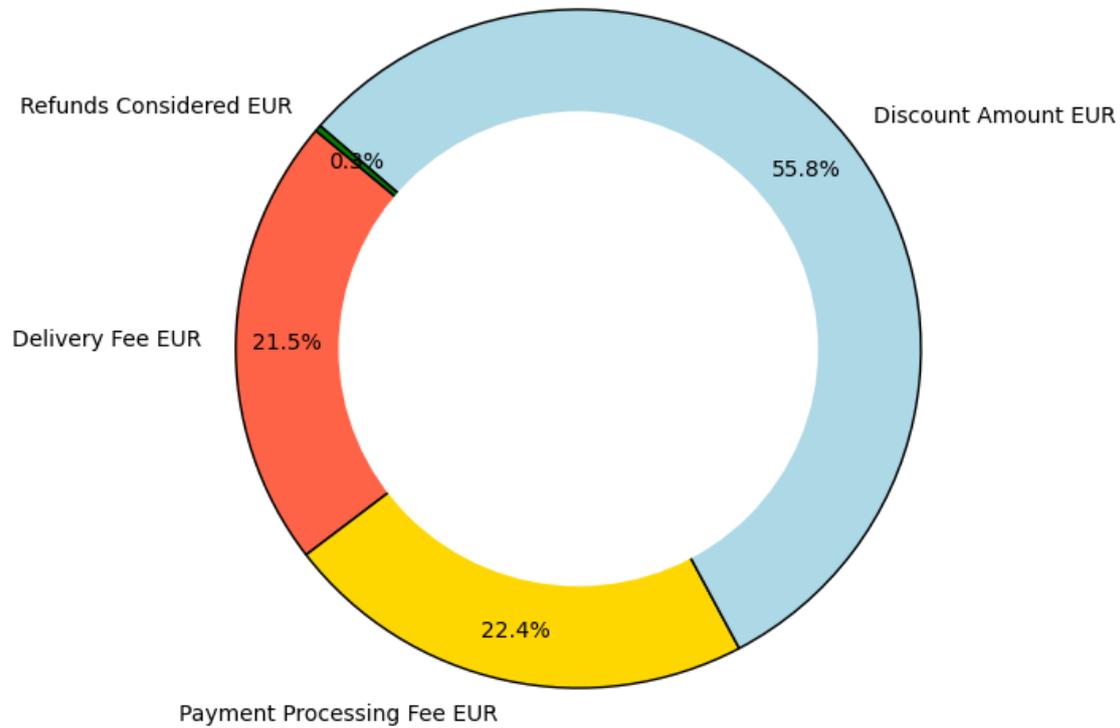


Fuente: Elaboración Propia.

Además, la distribución de los costes totales en la plataforma de delivery revela que los descuentos representan la mayor parte del gasto (55.8%), lo que sugiere que las promociones juegan un papel clave en la estrategia comercial. Como se observa en la Ilustración 22, le siguen los costes de procesamiento de pagos (22.4%) y las tarifas de entrega (21.5%), que tienen un impacto significativo en la rentabilidad de los pedidos. En contraste, los reembolsos considerados

son mínimos (0.3%), lo que indica que las devoluciones y ajustes no representan un factor relevante dentro de los costes operativos. Esta estructura de costes refuerza la importancia de optimizar las estrategias de descuentos y de logística para mejorar la rentabilidad de la plataforma.

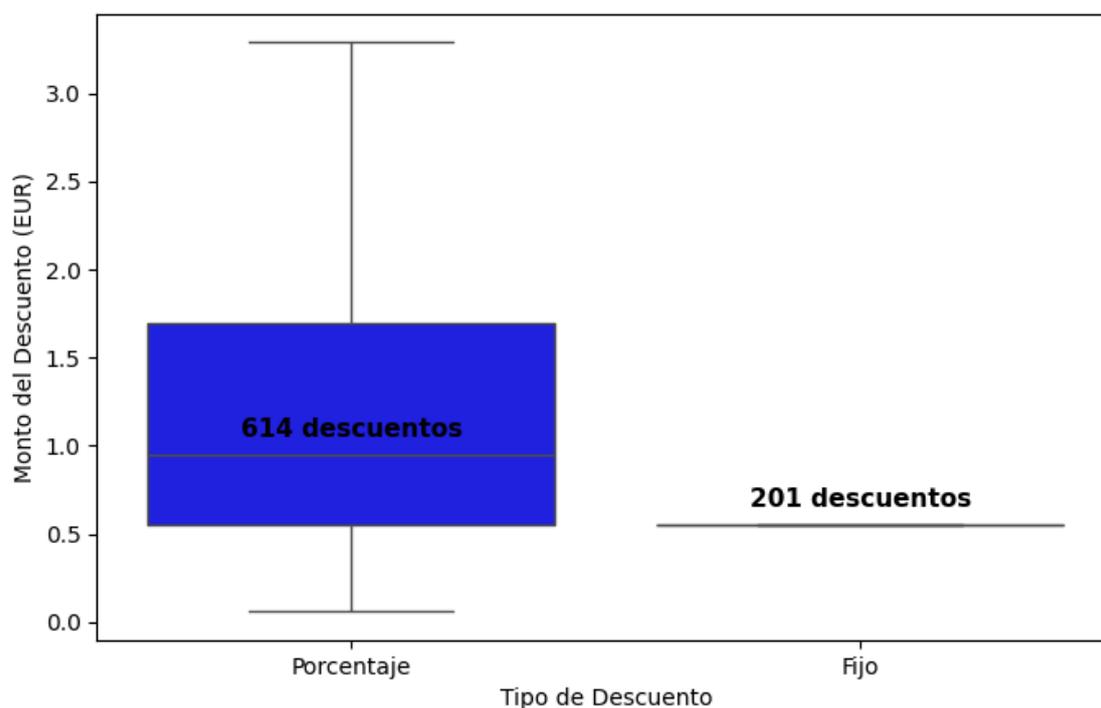
Ilustración 22. *Distribución de costes totales*



Fuente: Elaboración Propia.

Por último, el análisis de la distribución de descuentos revela que las promociones en porcentaje son las más frecuentes (614 pedidos), seguidas por los descuentos fijos (201 pedidos) y los pedidos sin descuento (185 pedidos). Además, se puede observar en la Ilustración 23 que los descuentos en porcentaje presentan una mayor variabilidad, lo que indica que su impacto en la rentabilidad depende directamente del valor del pedido. En contraste, los descuentos fijos, limitados a 0.5€, tienen un efecto más uniforme, pero al aplicarse en menos casos, su influencia en la rentabilidad global es menor.

Ilustración 23. *Distribución de descuentos por tipo*



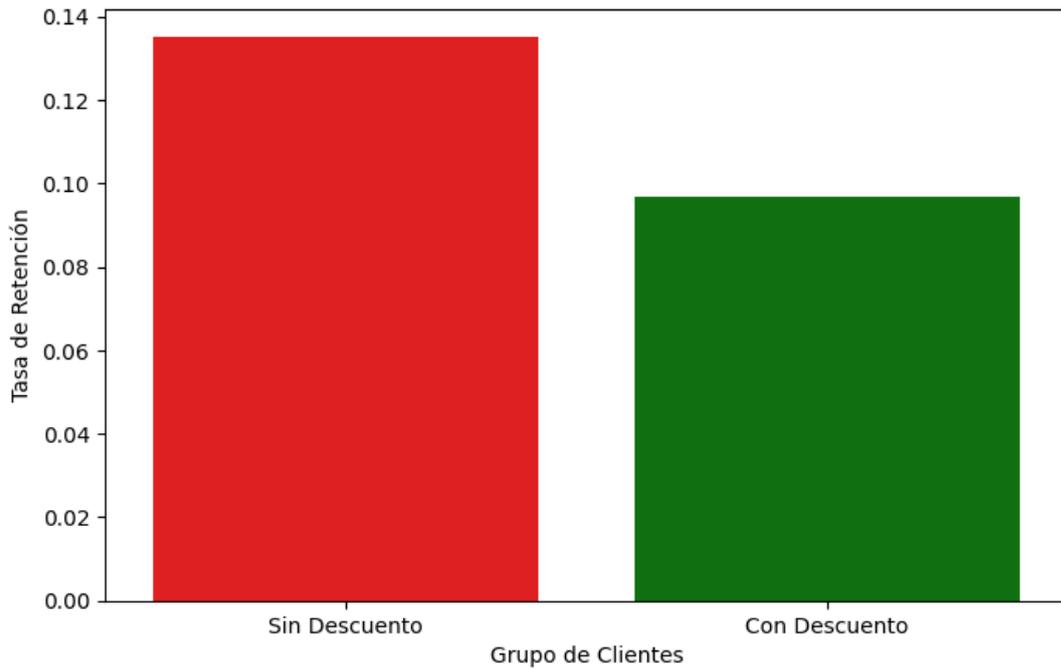
Fuente: Elaboración Propia.

Estos hallazgos refuerzan la importancia de una optimización en la estructura de costes, descuentos y estrategias de *pricing* para mejorar la rentabilidad general y reducir las pérdidas en pedidos de bajo valor.

4.5.2. Compartimiento de los clientes y pedidos

El análisis de la retención de clientes revela que la tasa de retención es ligeramente superior entre aquellos que no han recibido descuentos (13.5 %) en comparación con los que sí los han recibido (9.7 %). Como se muestra en la Ilustración 24, esta diferencia, aunque aparente, no resulta estadísticamente significativa según la prueba de Chi-cuadrado (p -valor: 0.1605). Esto sugiere que los descuentos no tienen un impacto claro en la probabilidad de que un cliente vuelva a realizar un pedido. En otras palabras, no existe evidencia suficiente para afirmar que ofrecer descuentos contribuya a mejorar la retención de clientes.

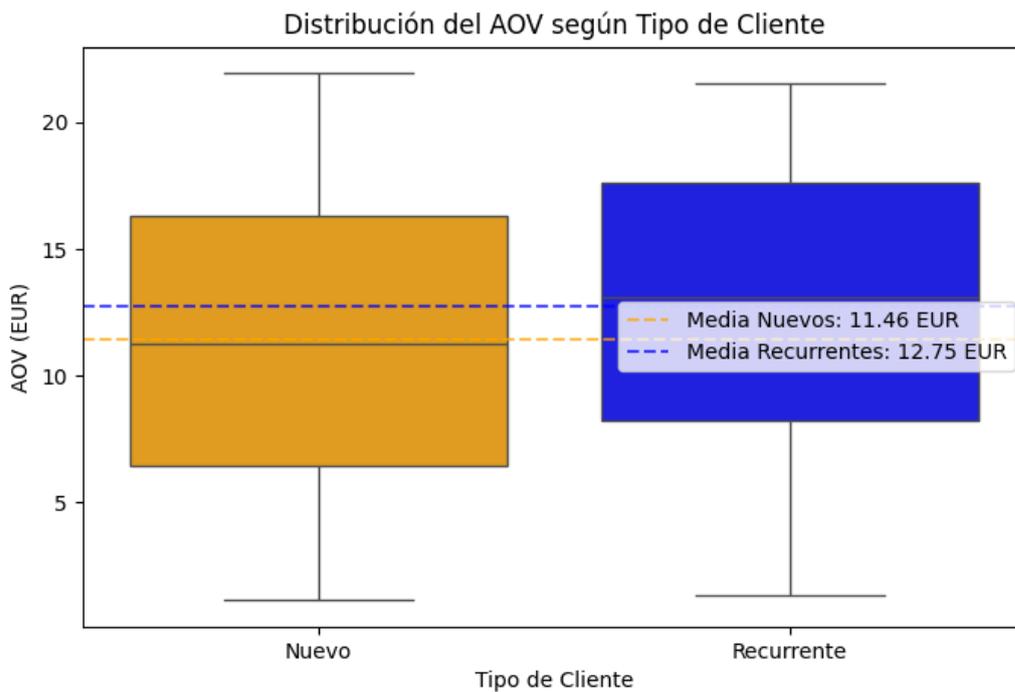
Ilustración 24. Impacto de los descuentos en la retención de clientes



Fuente: Elaboración Propia.

Por otro lado, el análisis del AOV revela una diferencia significativa entre clientes nuevos y recurrentes. La prueba T de Student arroja un p-valor de 0.0262, lo que confirma que los clientes recurrentes tienen un AOV significativamente mayor (12.75 EUR) en comparación con los nuevos (11.46 EUR).

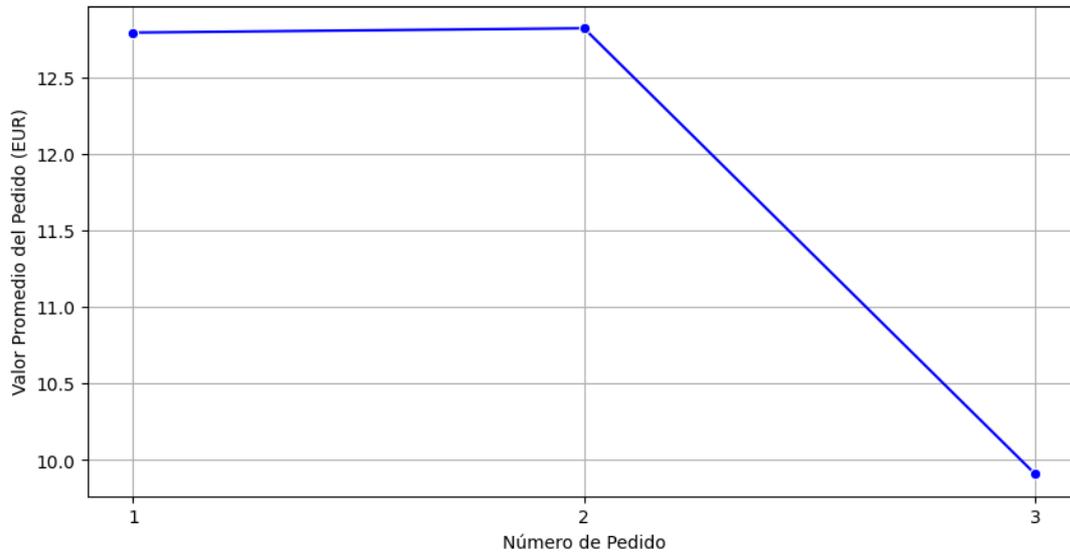
Ilustración 25. Distribución del AOV según el tipo de cliente



Fuente: Elaboración Propia.

Sin embargo, al analizar la evolución del AOV en clientes recurrentes, se aprecia una tendencia descendente. Como se muestra en la Ilustración 26, el AOV disminuye a medida que el cliente realiza más pedidos, pasando de 12.75 EUR en el primer pedido a aproximadamente 10 EUR en el tercero. Este comportamiento sugiere que los usuarios ajustan su nivel de gasto con el tiempo, posiblemente como respuesta a promociones iniciales o a cambios en sus hábitos de consumo.

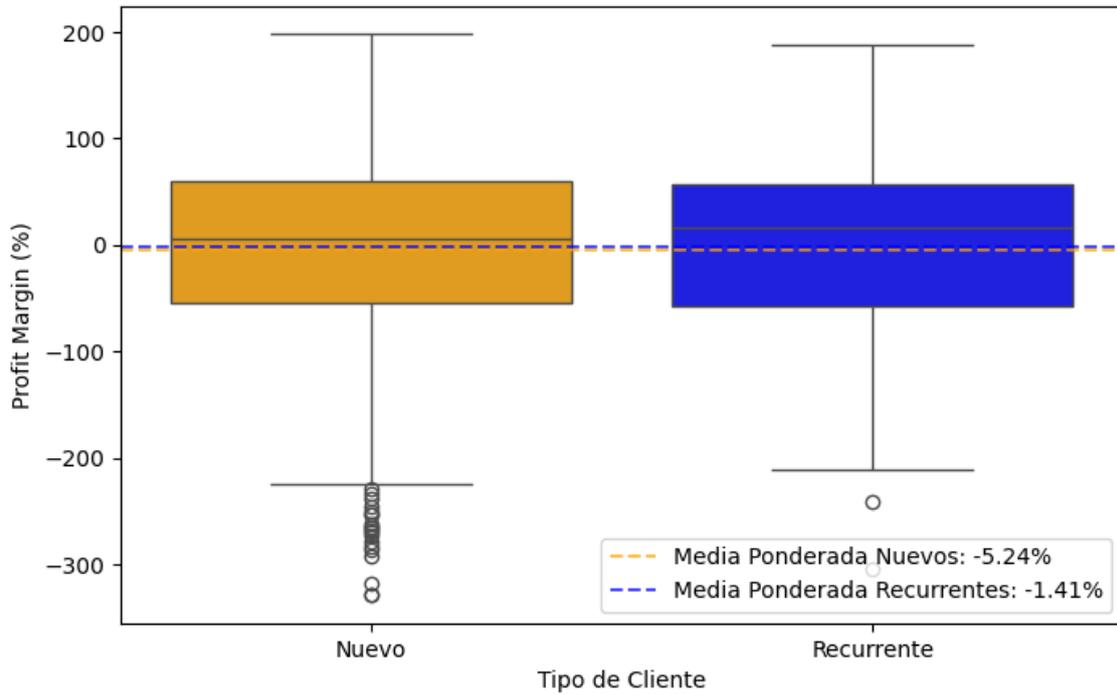
Ilustración 26. *Evolución del AOV en clientes recurrentes*



Fuente: Elaboración Propia.

Asimismo, al comparar el margen de beneficio entre clientes nuevos y recurrentes, se observa una diferencia estadísticamente significativa según la prueba t de Student (p-valor: 0.0171). Como se muestra en la Ilustración 27, los clientes nuevos presentan un margen de beneficio medio de -5.24 %, mientras que en los recurrentes es de -1.41 %. Aunque ambos grupos registran márgenes negativos, la menor pérdida asociada a los clientes recurrentes sugiere que estos generan un impacto menos perjudicial en la rentabilidad de la plataforma.

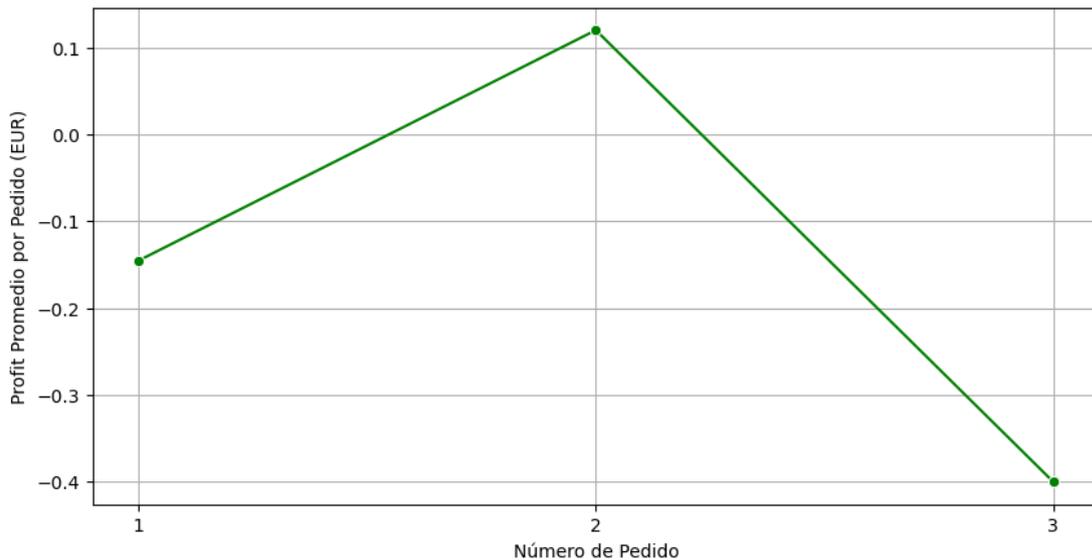
Ilustración 27. Distribución del Profit Margin (%) según tipo de cliente



Fuente: Elaboración Propia.

Finalmente, la evolución del beneficio medio por pedido en clientes recurrentes revela que, aunque inicialmente es positivo, cae a valores negativos en el tercer pedido. Esto refuerza la necesidad de estrategias que maximicen la rentabilidad de estos clientes a largo plazo.

Ilustración 28. Evolución del Profit en clientes recurrentes



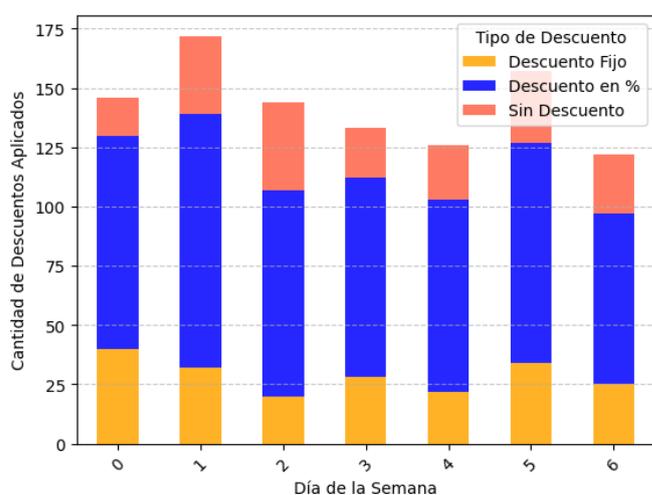
Fuente: Elaboración Propia.

Estos hallazgos destacan la importancia de diseñar estrategias de fidelización que no dependan exclusivamente de descuentos, sino que incorporen incentivos más sostenibles que fomenten la retención y, al mismo tiempo, optimicen la rentabilidad de la plataforma.

4.5.3. Descuentos: análisis y efecto en la rentabilidad

El análisis de los descuentos aplicados en la plataforma revela patrones claros en su distribución temporal. En términos de frecuencia, como se observa en la Ilustración 29, el día con mayor número de descuentos aplicados es el martes, mientras que el domingo es el día con menos descuentos (0 = Lunes, 6 = Domingo).

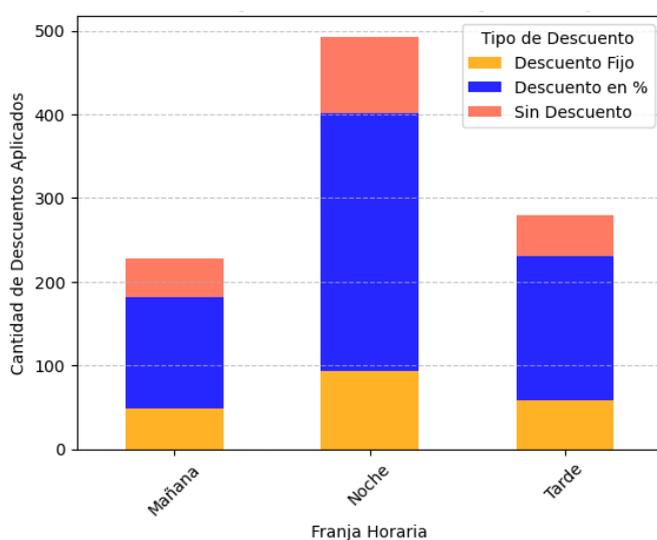
Ilustración 29. Frecuencia de tipos de descuento por día de la semana



Fuente: Elaboración Propia.

A nivel horario, la franja nocturna concentra la mayor cantidad de descuentos, en contraste con la mañana, que registra la menor aplicación de promociones.

Ilustración 30. Frecuencia de tipos de descuento por franja horaria

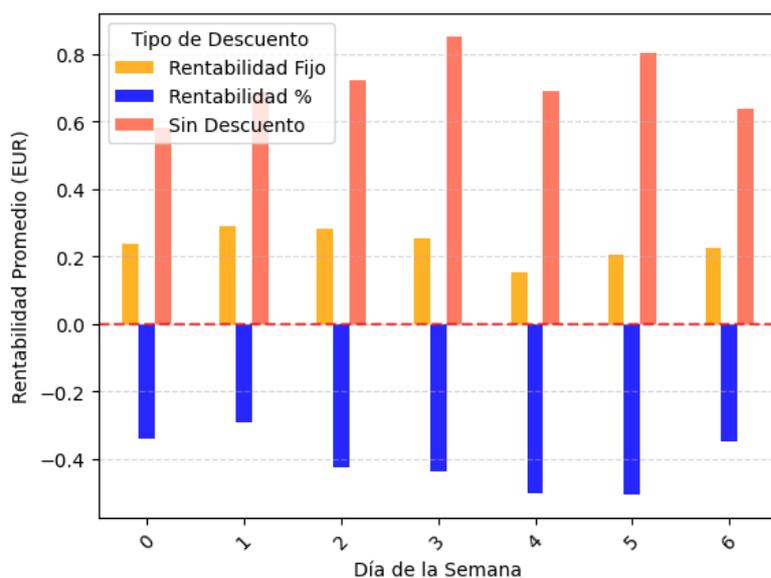


Fuente: Elaboración Propia.

Estos datos sugieren que las estrategias de descuento están alineadas con los momentos de mayor demanda, buscando incentivar las ventas en horarios y días estratégicos.

No obstante, al analizar su impacto en términos de rentabilidad, se observa un patrón claro según el tipo de descuento y el día de la semana. Los pedidos sin descuento generan mayores márgenes de beneficio de manera constante, mientras que los descuentos en porcentaje impactan negativamente en la rentabilidad. Los descuentos fijos, aunque reducen la rentabilidad, presentan un comportamiento más estable a lo largo de la semana.

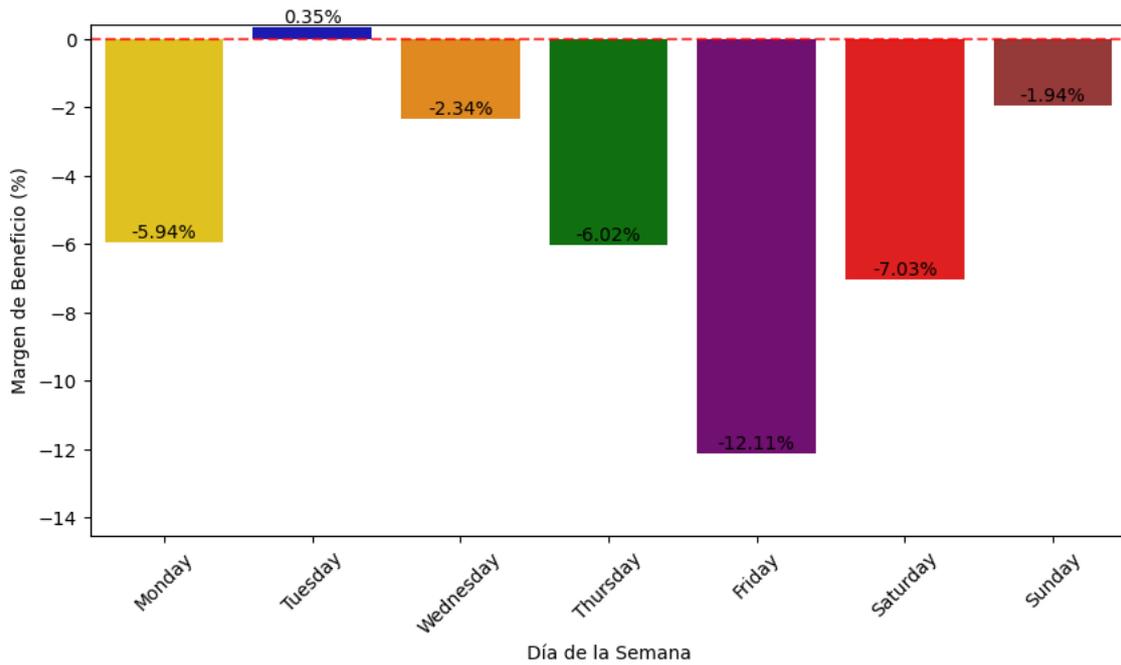
Ilustración 31. Rentabilidad promedio por tipo de descuento y día de la semana



Fuente: Elaboración Propia.

Por su parte, la Ilustración 32 muestra que los márgenes de beneficio tienden a ser más negativos los viernes y sábados, con un punto mínimo del -12,11 % el viernes, lo que sugiere una posible sobreinversión en descuentos durante estos días de alta demanda sin un retorno proporcional en rentabilidad. En cambio, el martes —que concentra una gran parte de las promociones— es el único día con rentabilidad positiva, lo que podría abrir la puerta a replicar estrategias similares en otras franjas poco rentables.

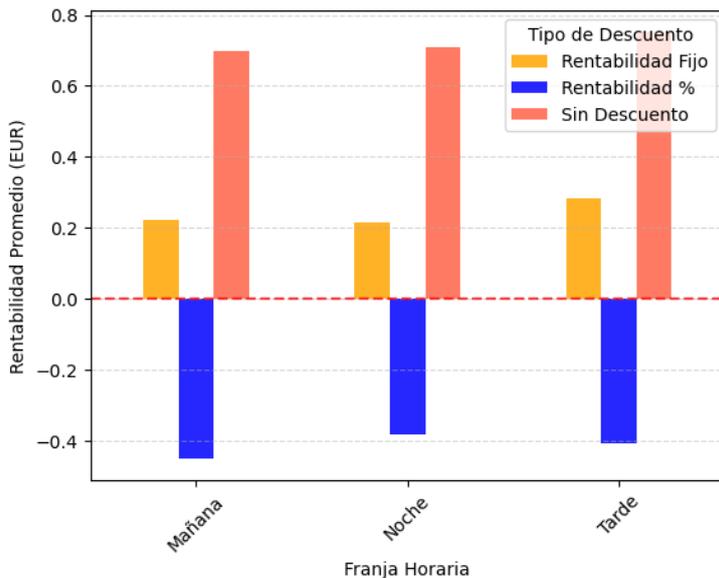
Ilustración 32. Margen de Beneficio Medio según el Día de la Semana



Fuente: Elaboración Propia.

Por otro lado, al analizar la rentabilidad según la franja horaria, la Ilustración 33 que los descuentos en porcentaje afectan de manera negativa en todas las franjas, siendo más pronunciado durante la noche. En cambio, los descuentos fijos tienen un impacto más moderado y predecible, mientras que los pedidos sin descuento mantienen una rentabilidad significativamente superior en cualquier horario.

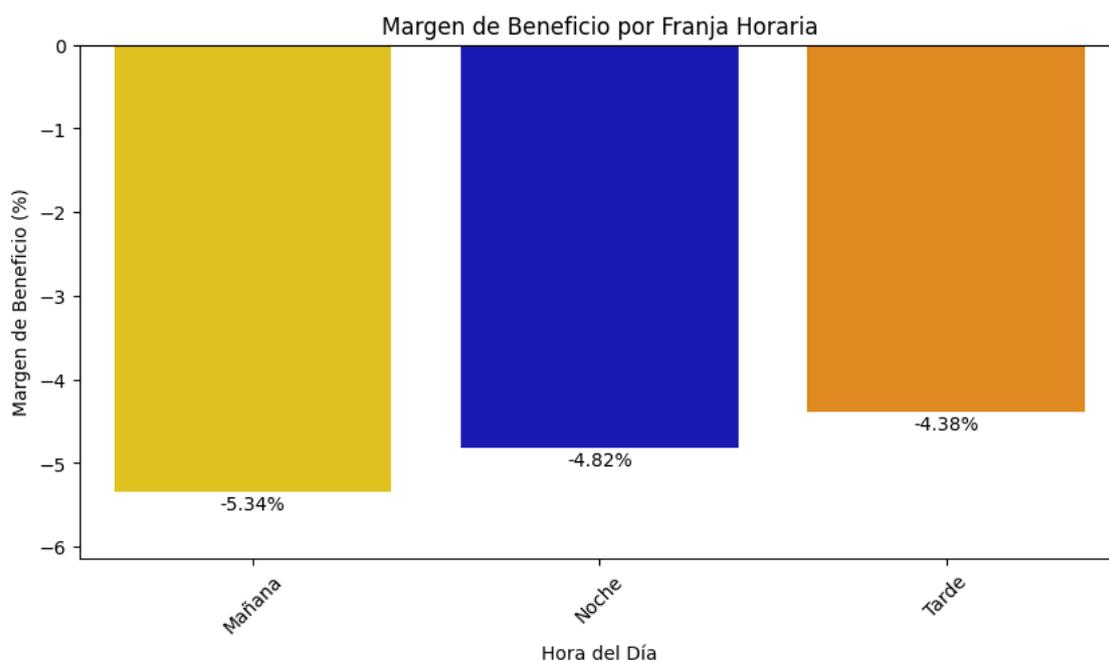
Ilustración 33. Rentabilidad promedio por tipo de descuento y franja horaria



Fuente: Elaboración Propia.

Por su parte, la Ilustración 34 revela que la rentabilidad global también varía según el momento del día: es especialmente baja por la mañana (-5,34 %) y durante la noche (-4,82 %), mientras que la tarde presenta un margen menos negativo (-4,38 %). Este patrón sugiere que la franja vespertina podría ofrecer un mayor margen de maniobra para campañas promocionales más eficientes desde el punto de vista económico.

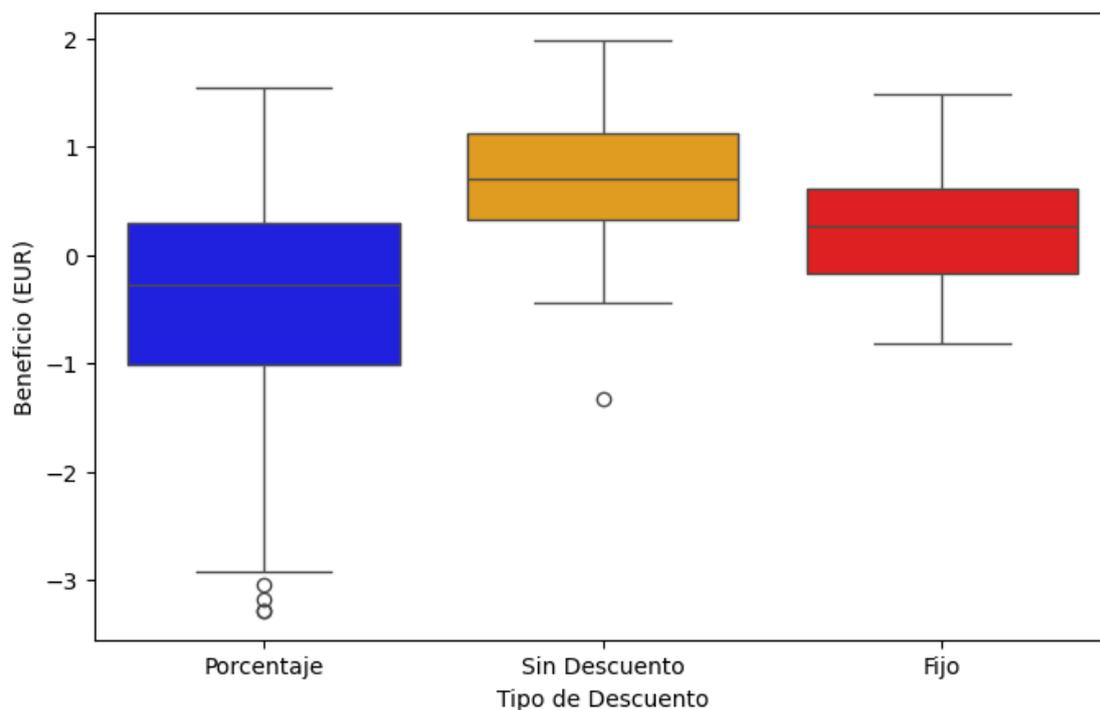
Ilustración 34. Margen de Beneficio Medio por Franja Horaria



Fuente: Elaboración Propia.

Desde una perspectiva de rentabilidad, los distintos tipos de descuento generan efectos claramente diferenciados en el desempeño financiero de la plataforma, como se muestra en la Ilustración 35. Se identificó una diferencia estadísticamente significativa en la rentabilidad entre los descuentos en porcentaje y los descuentos fijos (p -valor = 0.0000), así como entre aplicar o no un descuento. Estos resultados refuerzan la necesidad de diseñar promociones más estratégicas y selectivas, especialmente en franjas horarias y días en los que su efectividad resulta limitada.

Ilustración 35. *Impacto del tipo de descuento en la rentabilidad*

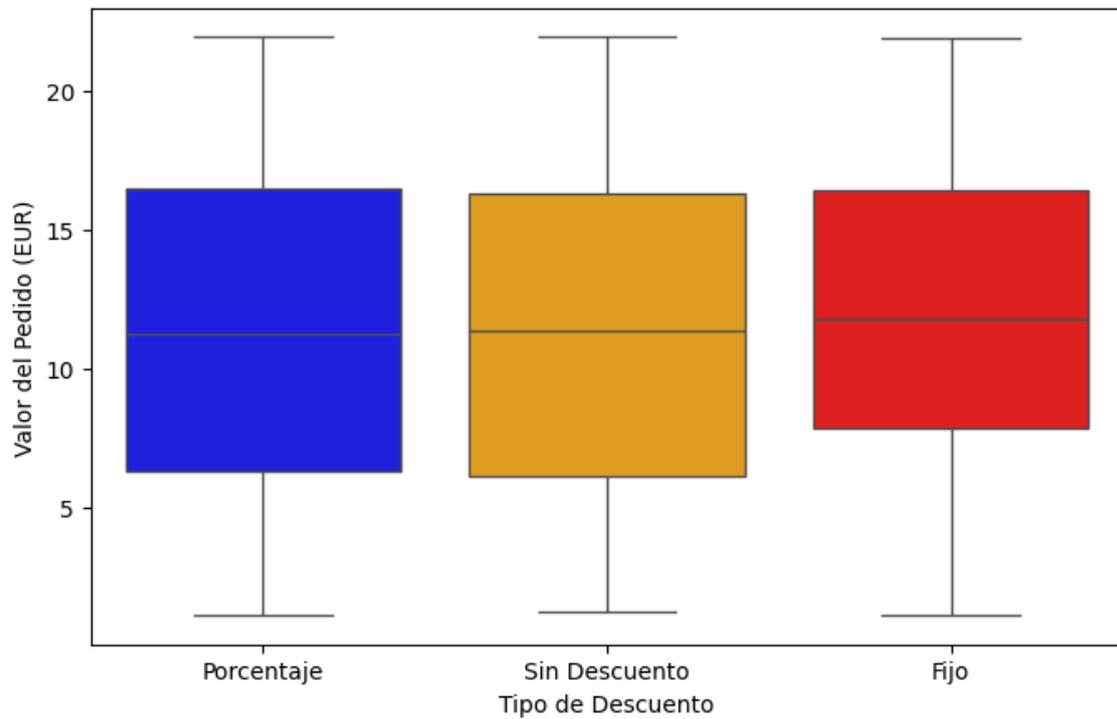


Fuente: Elaboración Propia.

Los descuentos en porcentaje tienden a reducir la rentabilidad de manera más pronunciada en comparación con los descuentos fijos, lo que sugiere que su impacto en el margen de beneficio es más agresivo. De hecho, la rentabilidad promedio es significativamente más alta en los pedidos sin descuentos.

El análisis del impacto del tipo de descuento en el AOV indica que no hay diferencias estadísticamente significativas entre los distintos tipos de descuento (p -valor = 0.4743). Aunque los pedidos con descuento fijo presentan un AOV ligeramente superior (12.04 EUR) en comparación con los descuentos en porcentaje (11.47 EUR) y la ausencia de descuentos (11.52 EUR), la prueba ANOVA confirma que estas diferencias no son lo suficientemente relevantes para concluir que el tipo de descuento influye directamente en el valor del pedido. Esto sugiere que otros factores, como la estrategia comercial o el comportamiento del consumidor, pueden tener un mayor peso en la determinación del importe del pedido.

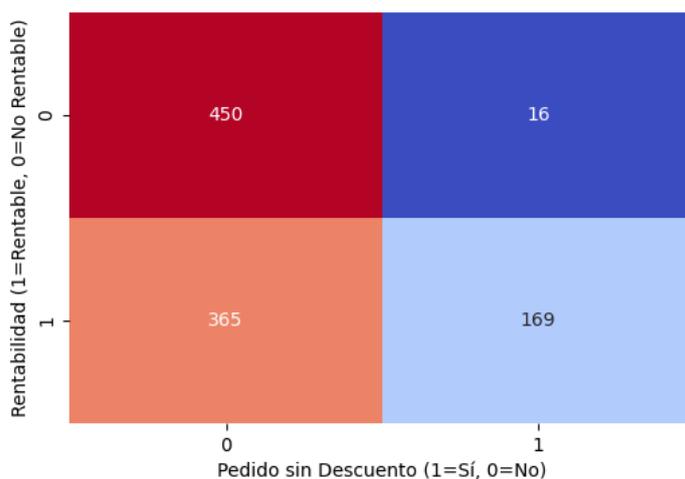
Ilustración 36. Impacto del tipo de descuento en el AOV



Fuente: Elaboración Propia.

Finalmente, la relación entre los descuentos y la rentabilidad se confirma mediante un análisis de contingencia. La prueba de chi-cuadrado ($p\text{-valor} = 0.0000$) demuestra que existe una relación estadísticamente significativa entre los pedidos sin descuento y la rentabilidad. En otras palabras, los pedidos sin descuentos tienen una mayor probabilidad de ser rentables en comparación con aquellos que reciben algún tipo de promoción.

Ilustración 37. Mapa de calor: relación entre descuento y rentabilidad

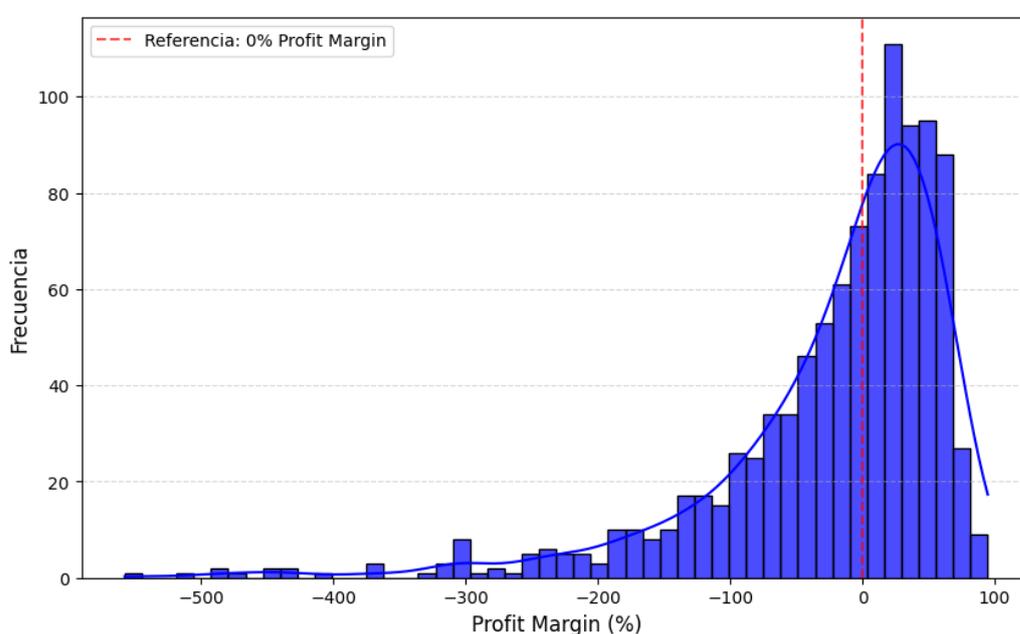


Fuente: Elaboración Propia.

Este hallazgo refuerza la necesidad de evaluar la estrategia de descuentos, priorizando su uso en escenarios donde realmente aporten valor sin comprometer de forma excesiva el margen de beneficio.

El análisis de la rentabilidad muestra la existencia de un grupo de pedidos con pérdidas extremadamente elevadas, como se muestra en la Ilustración 38. En particular, se identificaron 141 pedidos con márgenes inferiores al -100%, lo que indica que los costes asociados a estos pedidos superaron ampliamente los ingresos obtenidos. En conjunto, estos pedidos generaron una pérdida total de -238.22 EUR, con una facturación acumulada de solo 127.32 EUR, reflejando un impacto negativo significativo en la sostenibilidad financiera de la plataforma.

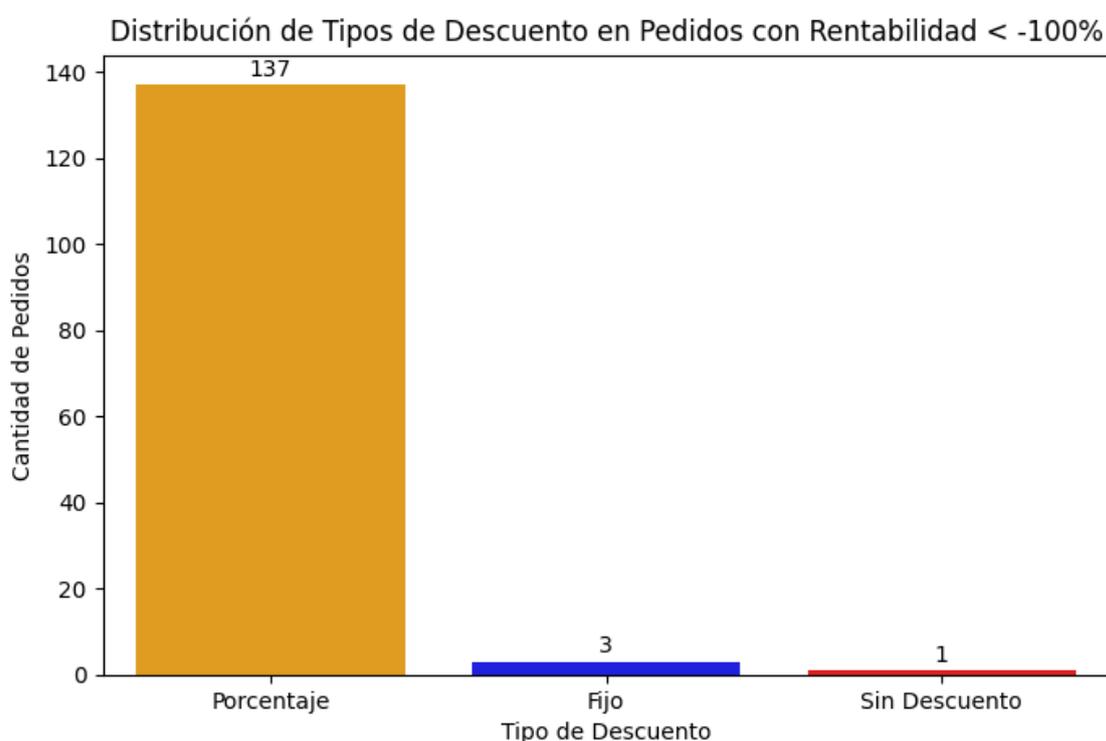
Ilustración 38. *Distribución del Profit Margin (%)*



Fuente: Elaboración Propia.

Uno de los factores determinantes en estas pérdidas es la aplicación de descuentos agresivos. La Ilustración 39 evidencia que, de los 141 pedidos con una rentabilidad inferior al -100 %, 140 estuvieron asociados a algún tipo de descuento. Este dato refuerza la hipótesis de que ciertas promociones pueden tener un impacto muy negativo en la rentabilidad. La gran mayoría de estos descuentos fueron en porcentaje (137 de los 140 casos), mientras que los descuentos fijos y la ausencia de descuentos fueron mucho menos frecuentes. Esto refuerza la idea de que los descuentos en porcentaje representan un mayor riesgo financiero para la plataforma.

Ilustración 39. *Distribución de tipos de descuento en pedidos con rentabilidad < -100%*



Fuente: Elaboración Propia.

Además, como muestra la Tabla 4, la comparación entre pedidos rentables y aquellos con márgenes inferiores a -100% revela una diferencia significativa en el AOV. Los pedidos con pérdidas extremas presentan un valor medio de pedido de 15.66 EUR, considerablemente superior al de los pedidos rentables (10.04 EUR). La prueba T de Student confirma que esta diferencia es estadísticamente significativa (p-valor: 0.0000), lo que sugiere que los descuentos están incentivando pedidos de mayor importe sin garantizar una rentabilidad sostenible. Adicionalmente, estos pedidos presentan un coste promedio 2.5 veces mayor que los rentables (2.59 EUR vs. 1.00 EUR) y aplican descuentos considerablemente más altos (1.87 EUR vs. 0.39 EUR), lo que demuestra que la combinación de promociones agresivas y costes operativos elevados puede generar pérdidas estructurales. A esto se suma que la comisión cobrada en estos pedidos es significativamente menor, con una tasa promedio del 6.49% frente al 27.30% de los pedidos rentables, lo que implica que, aunque el valor del pedido sea mayor, la plataforma recibe una menor proporción de ingresos por comisión, amplificando la pérdida de rentabilidad.

Tabla 4. Comparación entre pedidos rentables y pedidos con rentabilidad > -100%

	Métrica	Pedidos Rentables	Pedidos con Rentabilidad < -100%
0	Orden Promedio (AOV)	10.041311	15.657376
1	Coste Promedio	1.007079	2.592482
2	Descuento Medio (%)	5.617931	12.013955
3	Refund Medio	0.000000	0.011702
4	Margen Promedio	36.716627	-201.644549
5	Comisión (%)	27.298237	6.496369
6	Commission Fee EUR	1.621236	0.902979

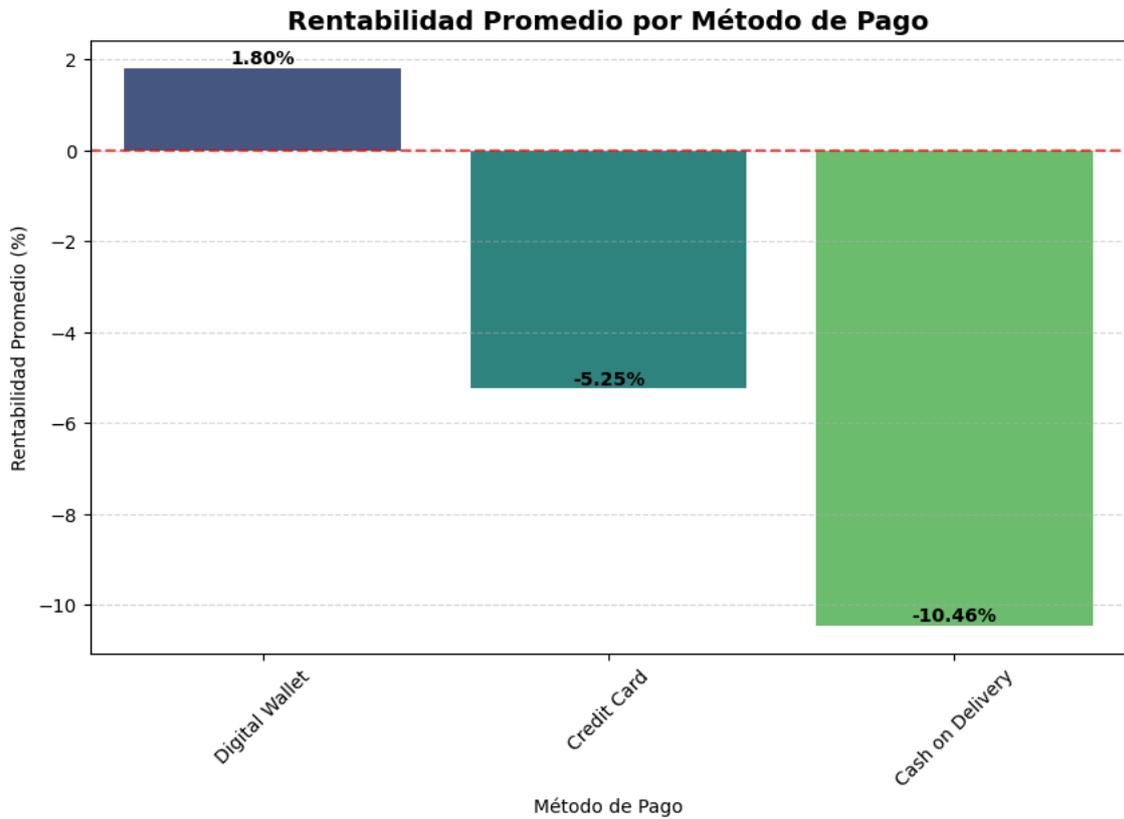
Fuente: Elaboración Propia.

Estos resultados subrayan la importancia de revisar la estrategia de descuentos, particularmente aquellos en porcentaje, para evitar que comprometan la rentabilidad general del negocio. Implementar controles más estrictos o limitaciones en el uso de ciertos descuentos podría ser clave para mitigar estos efectos adversos.

4.5.4. Métodos de pago: comparativa e impacto financiero

El análisis de rentabilidad según el método de pago muestra que las billeteras digitales *Digital Wallet* presentan el mayor margen de beneficio (1.80%), seguidas de las tarjetas de crédito (-5.25%) y el pago contra entrega (-10.46%). Como se muestra en la Ilustración 40, estas diferencias sugieren que la forma de pago puede tener un impacto relevante en la rentabilidad de los pedidos. Sin embargo, la prueba ANOVA realizada entre los diferentes métodos de pago indica que no hay evidencia estadísticamente significativa (p-valor: 0.1253) para afirmar que la rentabilidad varía en función del método utilizado. Esto sugiere que las diferencias observadas pueden deberse a otros factores no considerados en este análisis.

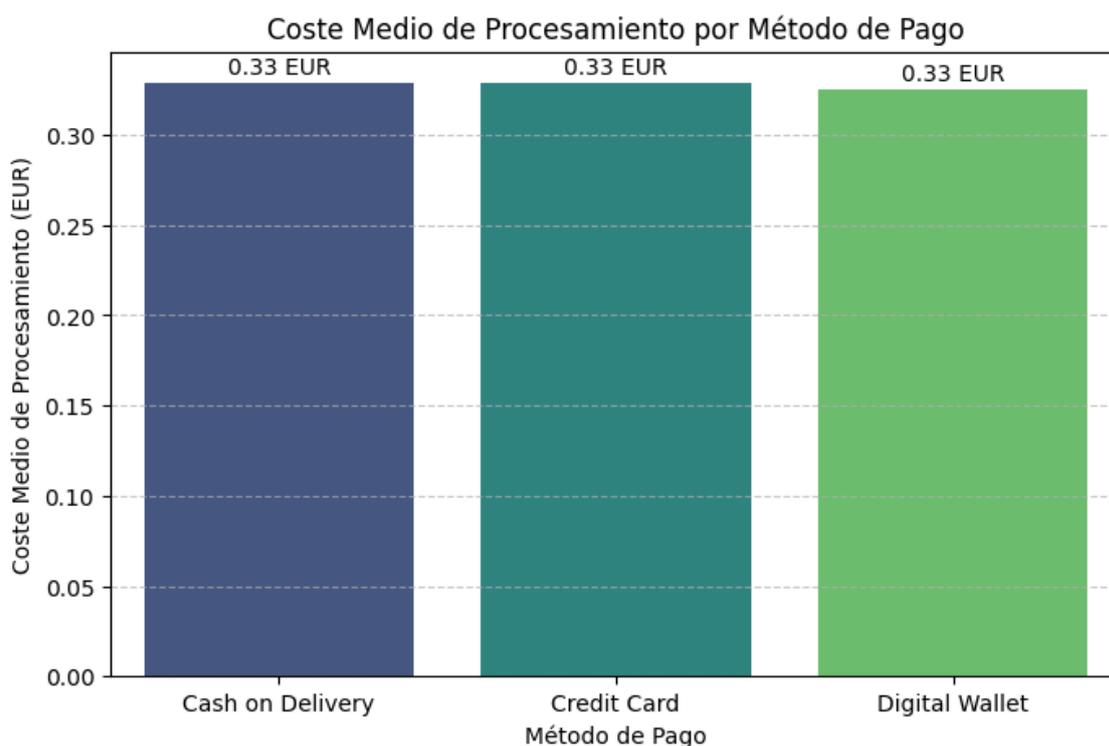
Ilustración 40. Rentabilidad promedio por método de pago



Fuente: Elaboración Propia.

Por otro lado, como muestra la Ilustración 41, el costo medio de procesamiento es uniforme en los tres métodos de pago, con un valor de 0.33 EUR por transacción. Esto indica que las diferencias en rentabilidad no están relacionadas con el coste de procesamiento, sino posiblemente con el comportamiento de los clientes, la tasa de conversión de pedidos o las características de cada método en la operativa de la plataforma.

Ilustración 41. *Coste medio de procesamiento por método de pago*



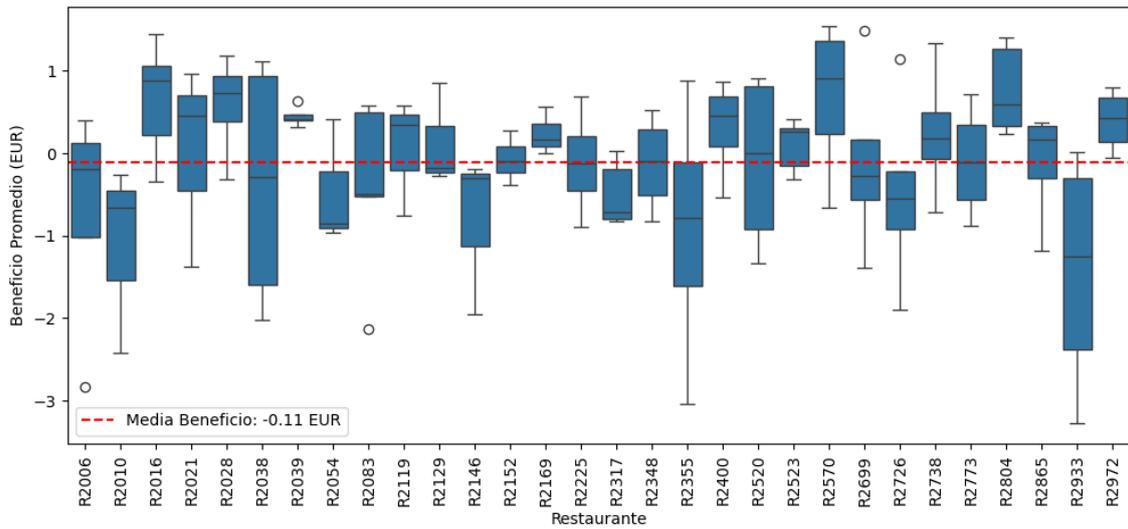
Fuente: Elaboración Propia.

Estos hallazgos resaltan la importancia de seguir explorando el impacto de los métodos de pago en la rentabilidad y la experiencia del usuario, considerando factores adicionales como la tasa de cancelaciones o la fidelización de clientes según su método de pago preferido.

4.5.5. Rentabilidad y estrategia de los restaurantes de la plataforma

El análisis de la rentabilidad de los restaurantes en la plataforma muestra una diferencia significativa entre aquellos con mayor volumen de pedidos y aquellos con mayor margen de beneficio, tal como se observa en la Ilustración 42. Los 30 restaurantes con más pedidos presentan, en promedio, una rentabilidad negativa de -0.11 EUR por pedido y un margen de beneficio de -13.38%. A pesar de su alto número de transacciones (119 pedidos en total), su baja rentabilidad sugiere que operan con costes elevados o se ofrecen descuentos agresivos para estos restaurantes dentro de la plataforma.

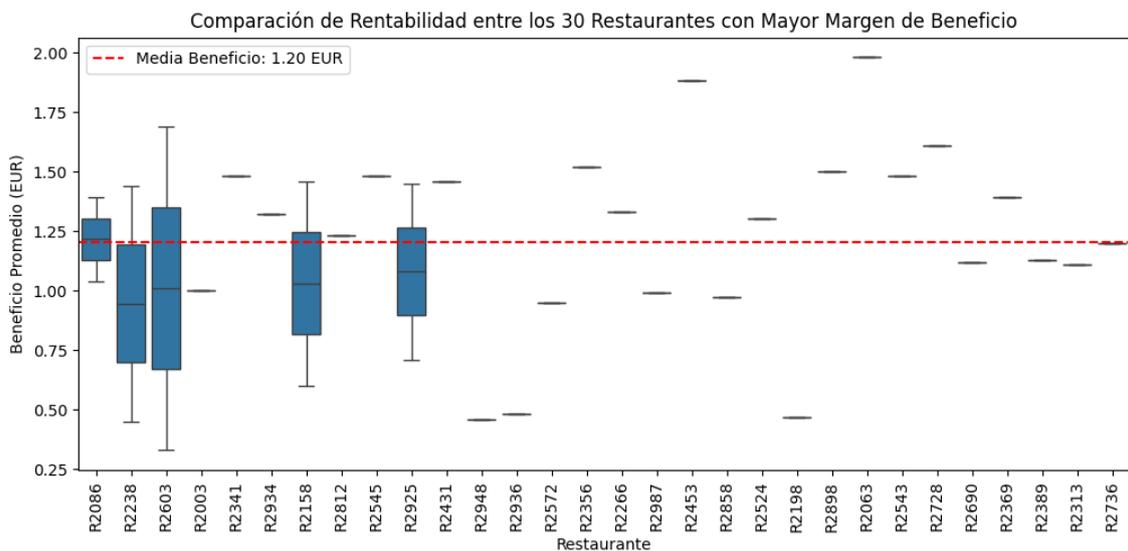
Ilustración 42. Comparación de rentabilidad entre los 30 restaurantes con más pedidos



Fuente: Elaboración Propia.

En contraste, la Ilustración 43 muestra que los 30 restaurantes con mayor margen de beneficio registran una rentabilidad promedio positiva de 1.20 EUR por pedido, con un margen del 69.94%. Sin embargo, su volumen de pedidos es significativamente menor (35 en total), lo que indica que la rentabilidad en la plataforma no depende únicamente de la cantidad de pedidos, sino de una estrategia de costes y comisiones más eficiente.

Ilustración 43. Comparación de rentabilidad entre los 30 restaurantes con mayor beneficio



Fuente: Elaboración Propia.

Estos hallazgos evidencian la necesidad de examinar tanto el modelo de negocio de cada restaurante como la estrategia de descuentos en la plataforma, puesto que un alto volumen de pedidos no siempre se traduce en una rentabilidad sostenible.

4.6. Conclusiones del análisis exploratorio

El Análisis Exploratorio de Datos permitió identificar patrones clave en la rentabilidad de la plataforma, revelando factores que afectan la sostenibilidad del modelo de negocio. En términos generales, se evidenció que los costes totales superan los ingresos, lo que genera una estructura operativa no rentable. El impacto de los descuentos en la rentabilidad fue uno de los hallazgos más relevantes, ya que los descuentos en porcentaje reducen de manera significativa los márgenes de beneficio, mientras que los descuentos fijos tienen un impacto más estable. Asimismo, se identificó que los pedidos sin descuento tienen una mayor probabilidad de ser rentables.

Otro hallazgo clave fue la estructura de comisiones aplicada por Zomato. A través del análisis de regresión, se confirmó que la plataforma emplea un modelo de comisiones mixto, combinando una tarifa fija con una comisión variable decreciente en función del valor del pedido. Esto provoca que los pedidos de menor importe soporten tasas de comisión excepcionalmente altas, lo que impacta negativamente en la rentabilidad de ciertos restaurantes. La falta de transparencia en estos esquemas dificulta la comparación con otras plataformas y resalta la necesidad de optimizar la estructura de comisiones.

El análisis de los métodos de pago mostró que, aunque existen diferencias en rentabilidad entre billeteras digitales, tarjetas de crédito y pagos en efectivo, estas diferencias no son estadísticamente significativas. Sin embargo, la plataforma podría beneficiarse de estrategias que incentiven métodos de pago más rentables para minimizar pérdidas.

En cuanto a la rentabilidad de los restaurantes, se observó que los establecimientos con mayor volumen de pedidos no necesariamente son los más rentables. Los 30 restaurantes con más pedidos presentaron márgenes negativos en comparación con aquellos con menor volumen, pero mayores márgenes de beneficio. Esto sugiere que una alta demanda no garantiza rentabilidad y que las estrategias de costes y comisiones juegan un papel crucial.

Estos hallazgos sientan las bases para la siguiente fase, en la que se desarrollan y validan modelos matemáticos capaces de estimar y optimizar la tasa de comisión y los descuentos en función de las variables identificadas. Al incorporar factores como los costes totales, el valor de los pedidos, la eficiencia logística y la estructura de comisiones, los algoritmos de *machine learning* podrán evaluar y predecir el impacto de distintas estrategias comerciales sobre la rentabilidad y la fidelización. En la próxima sección se describen los modelos seleccionados, su implementación y el proceso de validación, con el objetivo de ofrecer recomendaciones prácticas que fortalezcan la competitividad y la sostenibilidad financiera de la plataforma.

5. Desarrollo y Validación del Modelo Matemático

El análisis exploratorio de datos ha revelado que la rentabilidad de las plataformas de *food delivery* depende tanto de los costes operativos como de estrategias comerciales que impactan la fidelización y sostenibilidad del negocio, especialmente en lo que respecta a descuentos y comisiones. Para traducir estos hallazgos en herramientas predictivas, esta sección desarrolla y valida modelos de *machine learning* capaces de estimar y optimizar la tasa de comisión y los descuentos en función de variables clave como el valor del pedido, la estructura de costes y la retención de clientes. Su implementación busca proporcionar un marco cuantitativo que facilite la toma de decisiones estratégicas y maximice la rentabilidad de la plataforma.

5.1. Desarrollo del modelo

Para evaluar el impacto de las estrategias de fidelización en la rentabilidad y retención de clientes en aplicaciones de *food delivery*, se han desarrollado modelos predictivos y explicativos basados en *machine learning*. Se han seleccionado algoritmos avanzados que permiten tanto la predicción de variables clave, siendo estas *Discount Rate (%)* y *Commission Rate (%)* como la interpretación de los factores más relevantes que afectan estos indicadores.

5.1.1. Selección de variables

Para reducir la dimensionalidad y seleccionar las variables más relevantes, se partió de un conjunto inicial de características (*Order Value EUR*, *Profit Margin (%)*, *Delivery Fee EUR*, *Payment Processing Fee EUR*, *Refunds Considered EUR*, *Delivery Time (min)*, *Rentable*, *Retention*).

Posteriormente, se aplicó LASSO (*Least Absolute Shrinkage and Selection Operator*), una técnica de regresión regularizada que penaliza los coeficientes menos relevantes, para entrenar los modelos de Random Forest y XGBoost. Como resultado, se retuvieron las siguientes variables clave:

- *Discount Rate (%)*: *Order Value EUR*, *Profit Margin (%)*, *Delivery Time (min)*, *Rentable*)
- *Commission Rate (%)*: *Order Value EUR*, *Profit Margin (%)*, *Delivery Time (min)*, *Rentable*)

Este proceso garantizó que solo se retuvieran aquellas características con mayor poder predictivo y relevancia para explicar las variaciones en la tasa de descuento y en la tasa de comisión. En cambio, para LightGBM y Redes Neuronales, se emplearon todas las variables originales, sin realizar este proceso de selección previa mediante LASSO.

5.1.2. Modelos utilizados

Se han implementado cuatro tipos de modelos para cada una de las variables objetivo:

- Random Forest: Modelo basado en múltiples árboles de decisión, útil para capturar relaciones no lineales.
- XGBoost (Extreme Gradient Boosting): Modelo de *boosting*, altamente eficiente y utilizado en competiciones de predicción.
- LightGBM: Variante de *boosting* más rápida y eficiente en el manejo de conjuntos de datos extensos.
- Redes Neuronales: Arquitectura de *deep learning* basada en capas densas con activación ReLU y optimización mediante Adam.

Estos modelos fueron entrenados y evaluados utilizando una división inicial 80-20 de los datos, donde el 80% se destinó al entrenamiento y el 20% a la validación.

5.2. Validación y evaluación del modelo

Para evaluar el rendimiento de los modelos, se emplearon las siguientes métricas:

- Mean Absolute Error (MAE): Error medio absoluto en unidades monetarias.
- Root Mean Squared Error (RMSE): Raíz del error cuadrático medio, útil para penalizar errores grandes.
- Coeficiente de Determinación (R^2): Mide qué porcentaje de la variabilidad de los datos es explicada por el modelo.

5.2.1. Validación cruzada

Para garantizar la robustez de los modelos, se utilizó validación cruzada mediante GridSearchCV y RandomizedSearchCV, aplicando K-Fold con 3 particiones ($cv=3$) en la optimización de hiperparámetros. Esta técnica permitió evaluar la estabilidad del modelo y evitar sobreajuste.

Para reforzar este análisis, se podría aplicar K-Fold con 5 particiones ($cv=5$), aumentando la estabilidad de la estimación de los parámetros óptimos.

5.2.2. Comparación de resultados

A continuación, se presenta la Tabla 5, que compara el rendimiento de los distintos modelos utilizados en este estudio. La tabla muestra las métricas MAE, RMSE y R^2 , permitiendo

identificar cuál de los algoritmos evaluados ofrece la mejor capacidad predictiva para la tasa de descuento y la tasa de comisión.

Tabla 5. Comparación de modelos y métricas de rendimiento

Modelo	MAE	RMSE	R²
Random Forest - Commission Rate (%)	3.7970	6.0094	0.9202
Random Forest - Discount Rate (%)	3.2559	4.2450	0.3452
XGBoost - Commission Rate (%)	3.9795	6.8123	0.8975
XGBoost - Discount Rate (%)	3.5096	4.2644	0.3392
Red Neuronal - Commission Rate (%)	4.6075	8.1647	0.8530
Red Neuronal - Discount Rate (%)	3.0841	3.8089	0.4729
LightGBM - Commission Rate (%)	3.7993	6.7591	0.8991
LightGBM - Discount Rate (%)	3.2031	4.0399	0.4070

Fuente: Elaboración Propia.

Los resultados indican que, para la tasa de comisión, el modelo de Random Forest obtuvo el mejor rendimiento con un R² de 0.9202, destacándose por su alta capacidad explicativa. En cuanto a la tasa de descuento, la Red Neuronal mostró el mejor desempeño, con un R² de 0.4729, aunque este valor sigue siendo moderado, lo que sugiere que pueden existir otros factores no contemplados en la modelización actual. Este mejor resultado podría atribuirse a la capacidad de la red neuronal para capturar patrones no lineales complejos y relaciones ocultas entre las variables, que otros modelos no logran identificar con la misma eficacia. En conjunto, los resultados muestran que los modelos son estadísticamente significativos. En el caso de la comisión, explican una proporción muy elevada de la variabilidad observada en la variable dependiente, mientras que para la tasa de descuento el poder explicativo es moderado, aunque suficiente para identificar patrones relevantes.

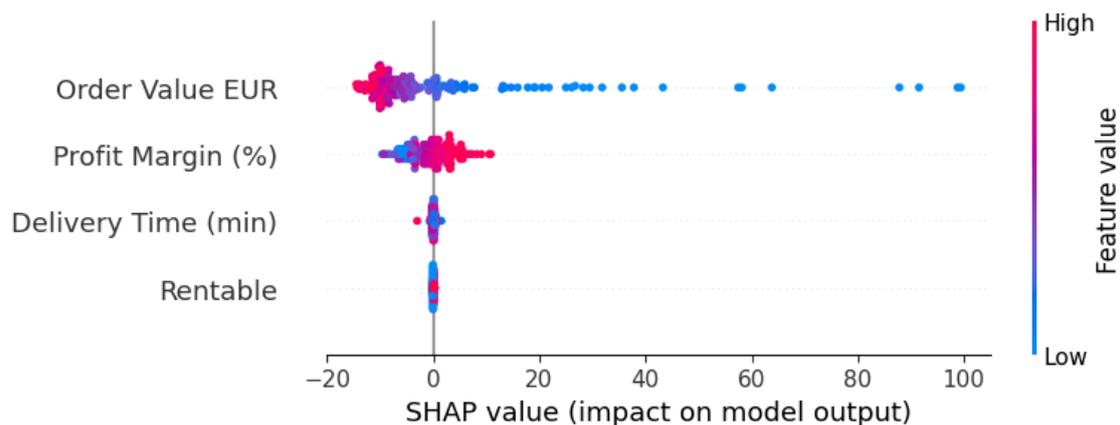
Por tanto, se seleccionó el modelo de Random Forest como modelo final para predecir la tasa de comisión, y la Red Neuronal como modelo final para estimar la tasa de descuento, al ser los que ofrecieron el mejor equilibrio entre precisión (MAE y RMSE) y capacidad explicativa (R²) dentro de sus respectivas categorías.

5.3. Interpretabilidad y explicabilidad

Los modelos de *machine learning* utilizados en este estudio, como Random Forest, XGBoost, LightGBM y Redes Neuronales, ofrecen un alto poder predictivo, pero presentan un desafío en términos de interpretabilidad, ya que operan como cajas negras. Para mejorar la comprensión de los factores que influyen en sus predicciones, se empleó SHAP (SHapley Additive exPlanations), un método que permite analizar el impacto de cada variable en las decisiones del modelo. SHAP proporciona una visión dual del impacto de las variables: a nivel global, identificando los factores que más contribuyen a las predicciones generales, y a nivel local, permitiendo entender cómo influyen las características en cada observación individual.

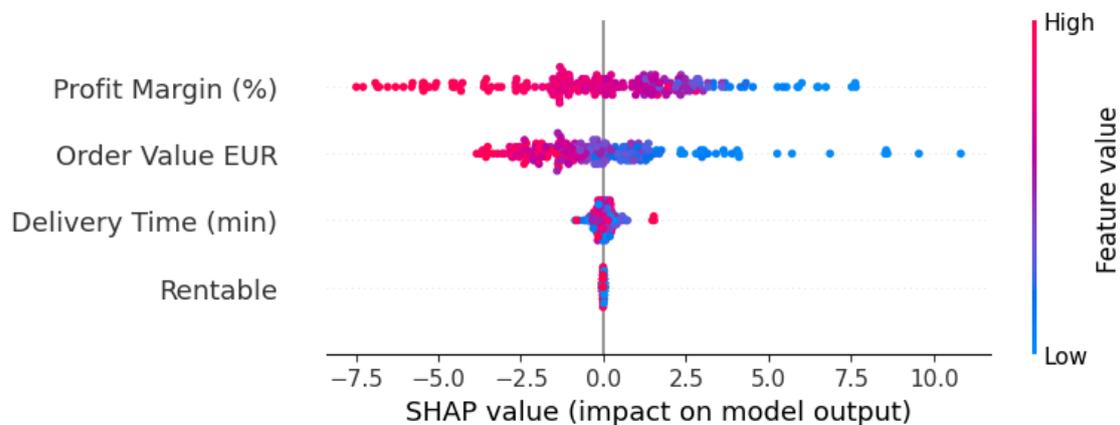
A continuación, se presentan los SHAP summary plots de cada modelo y variable objetivo. En estos gráficos, cada punto representa un valor SHAP, donde el color indica si el valor de la variable es alto (rojo) o bajo (azul), permitiendo visualizar cómo los cambios en cada característica afectan la predicción del modelo.

Ilustración 44. SHAP summary plot - Random Forest (Commission Rate (%))



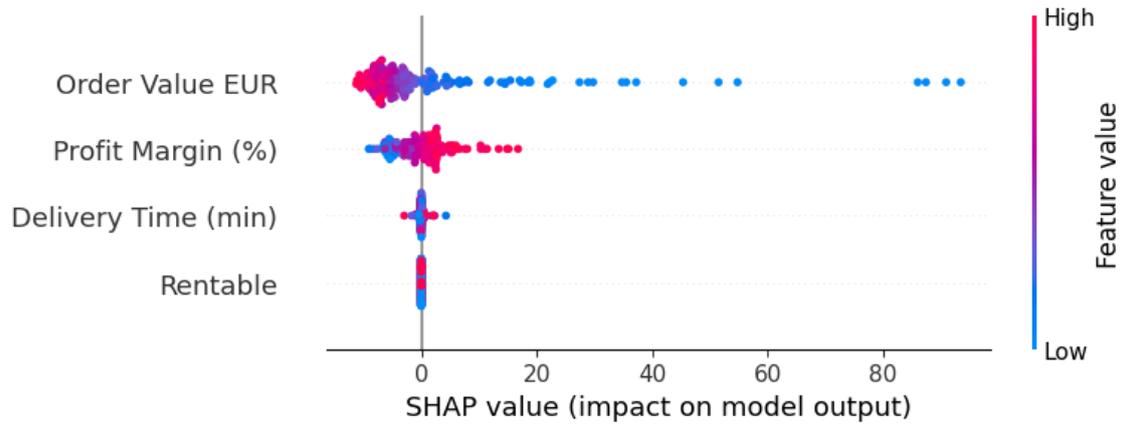
Fuente: Elaboración Propia.

Ilustración 45. SHAP summary plot - Random Forest (Discount Rate (%))



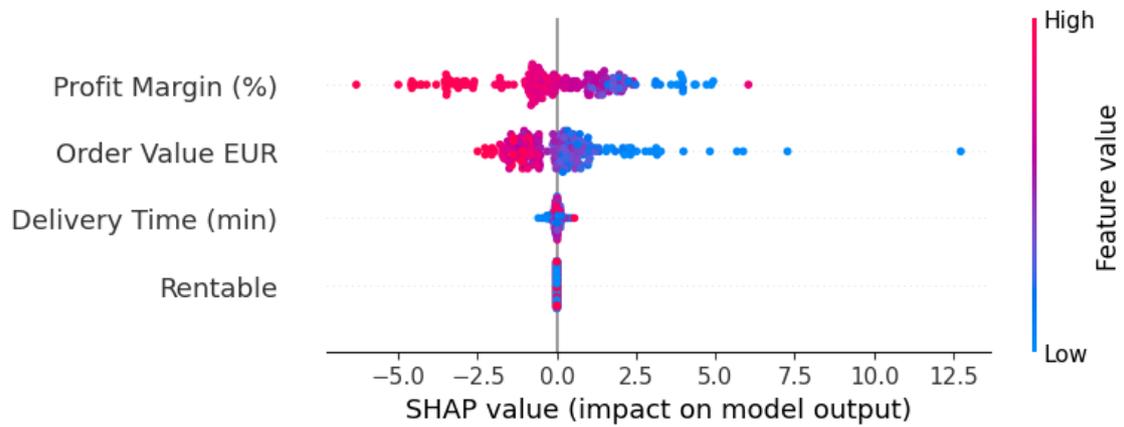
Fuente: Elaboración Propia.

Ilustración 46. SHAP summary plot - XGBoost (Commission Rate (%))



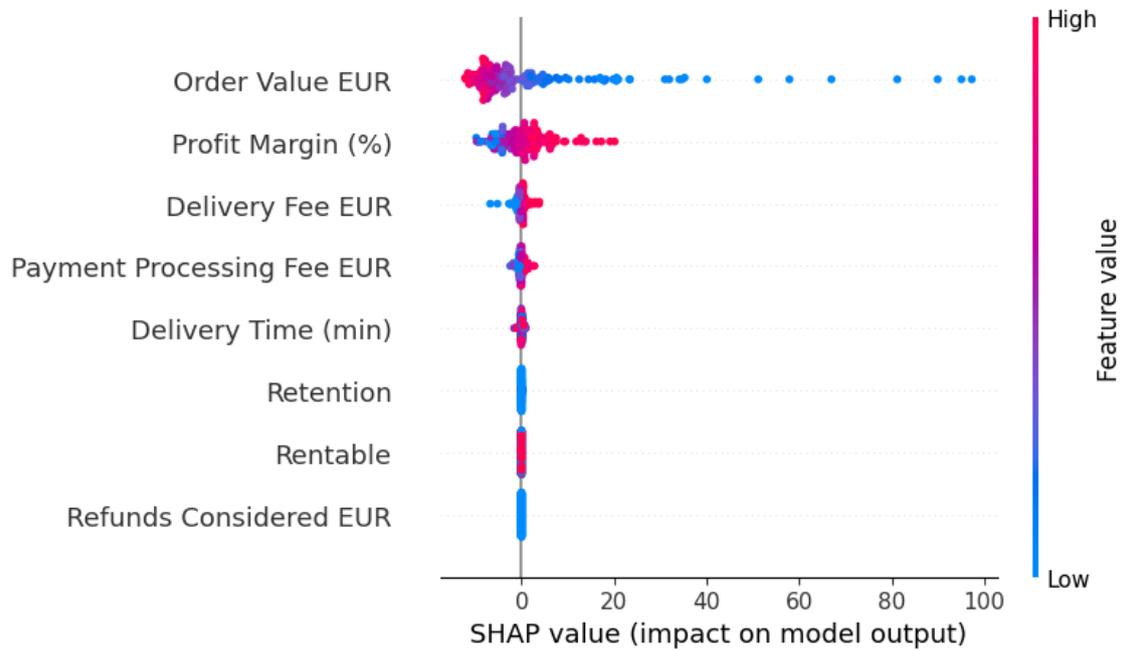
Fuente: Elaboración Propia.

Ilustración 47. SHAP summary plot - XGBoost (Discount Rate (%))



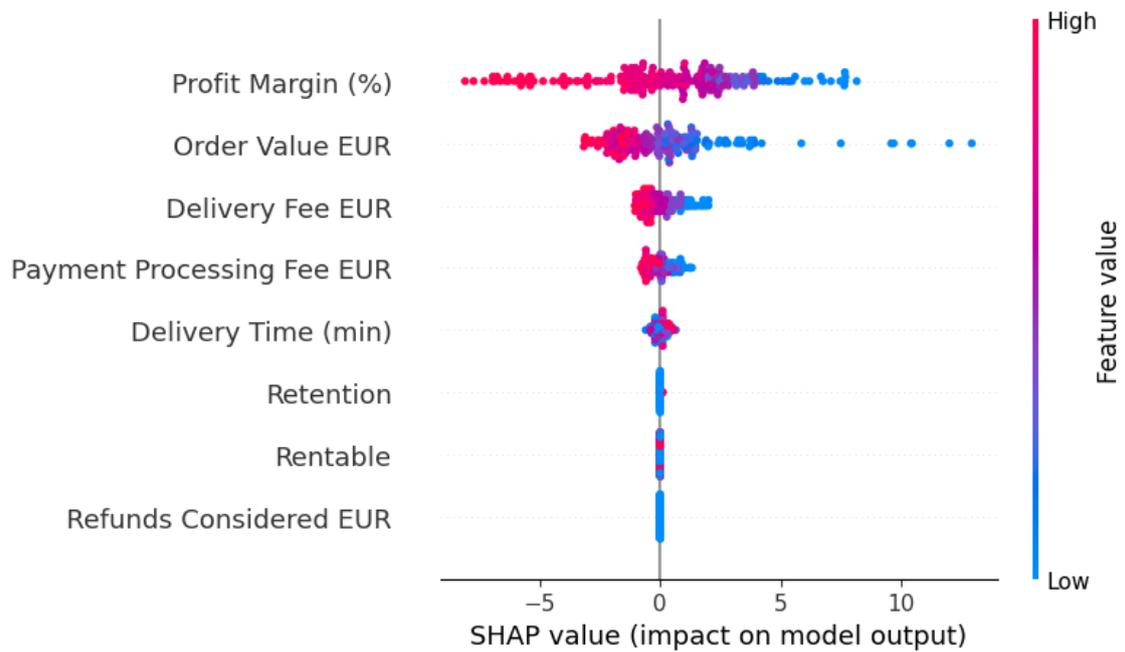
Fuente: Elaboración Propia.

Ilustración 48: SHAP summary plot - Red Neuronal (Commission Rate (%))



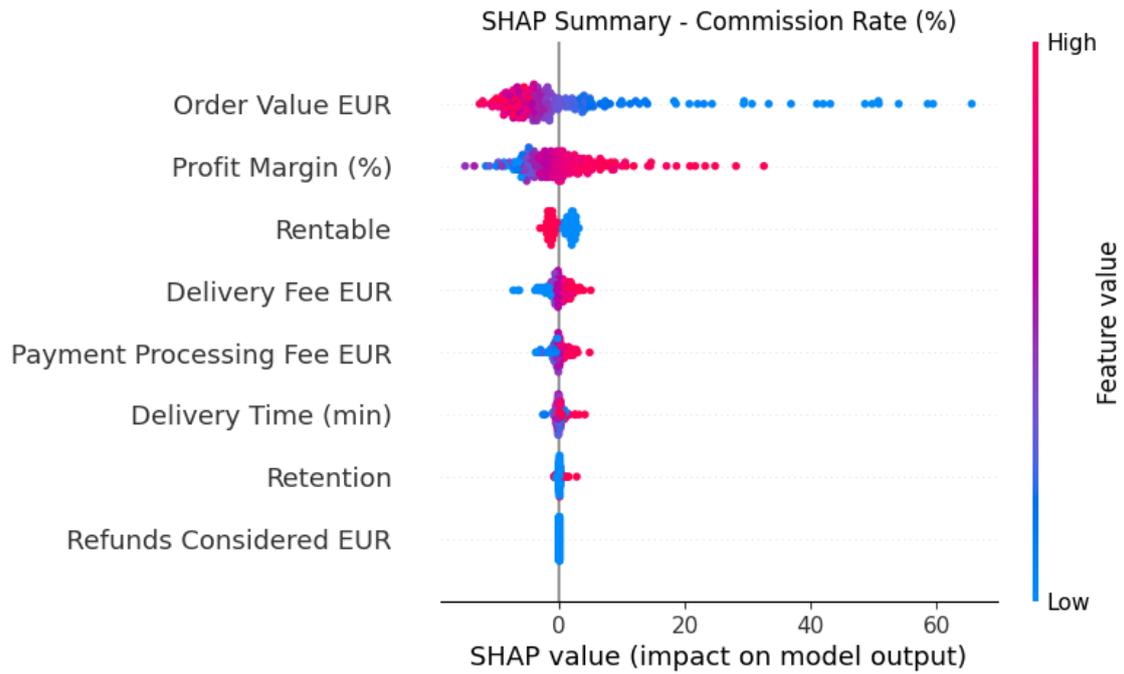
Fuente: Elaboración Propia.

Ilustración 49. SHAP summary plot - Red Neuronal (Discount Rate (%))



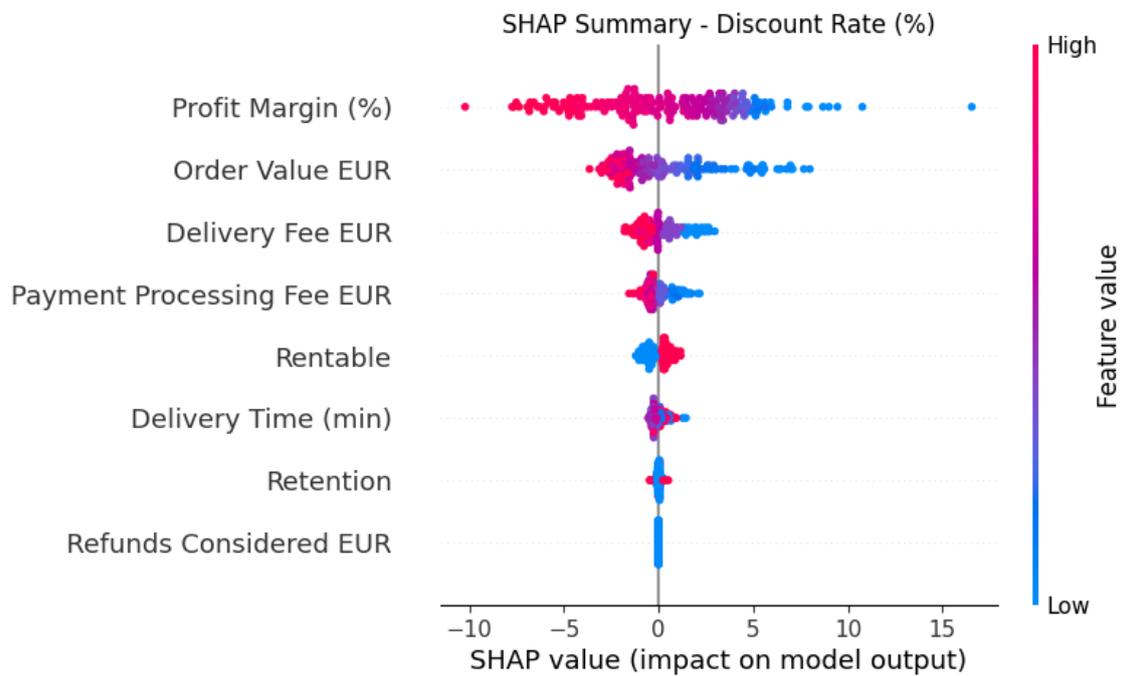
Fuente: Elaboración Propia.

Ilustración 50. SHAP summary plot - LightGBM (Commission Rate (%))



Fuente: Elaboración Propia.

Ilustración 51. SHAP summary plot - LightGBM (Discount Rate (%))



Fuente: Elaboración Propia.

Los análisis con SHAP permitieron identificar los factores más influyentes en la fijación de descuentos y comisiones, destacando los siguientes hallazgos:

- *Order Value EUR* es la variable con mayor impacto en la predicción de *Commission Rate (%)*, lo que indica que los pedidos de mayor valor están sujetos a tarifas de comisión más altas.
- *Profit Margin (%)* y *Delivery Time (min)* son determinantes en *Discount Rate (%)*, lo que sugiere que la rentabilidad y el tiempo de entrega juegan un papel clave en la fijación de descuentos.
- Variables como *Delivery Fee EUR* y *Payment Processing Fee EUR* tienen un impacto menor en las predicciones, pero pueden ser relevantes en ciertos casos específicos, lo que indica que podrían influir en estrategias de *pricing* secundarias.

A través de estos resultados, se puede entender mejor qué factores influyen en la estrategia de fijación de comisiones y descuentos en plataformas de *food delivery*. Esta información permite optimizar las estrategias promocionales y mejorar la retención de usuarios sin comprometer la rentabilidad, al priorizar las variables que más inciden en los resultados de negocio.

5.4. Conclusiones y aplicabilidad del modelo

Los modelos desarrollados han permitido identificar con precisión los factores clave que influyen en la fijación de comisiones y descuentos dentro de una plataforma de *food delivery*. Se ha observado que *Order Value EUR* es la variable más determinante en la predicción de *Commission Rate (%)*, mientras que *Profit Margin (%)* y *Delivery Time (min)* tienen un impacto significativo en *Discount Rate (%)*.

En términos de rendimiento, el modelo de Random Forest obtuvo los mejores resultados en la predicción de la tasa de comisión, con un R^2 de 0.9202, lo que indica una alta capacidad explicativa y precisión en la predicción de esta variable. La superioridad de este modelo se debe a su capacidad para capturar relaciones no lineales y su robustez frente a datos con alta variabilidad, lo que lo hace especialmente adecuado para estimar *Commission Rate (%)*, donde los patrones de dependencia son más marcados. En cuanto a la tasa de descuento, la Red Neuronal mostró el mejor desempeño, con un R^2 de 0.4729, lo que sugiere que esta variable presenta una mayor complejidad en su predicción. La capacidad de las redes neuronales para modelar relaciones no lineales y patrones ocultos dentro de los datos explica su mejor rendimiento en este caso, aunque el R^2 sigue siendo moderado, lo que indica que hay factores adicionales que influyen en los descuentos y que no han sido considerados en este análisis.

Los resultados obtenidos proporcionan una base sólida para la toma de decisiones estratégicas en plataformas de *food delivery*. No obstante, para traducir estos hallazgos en

acciones concretas, es fundamental explorar qué estrategias pueden mejorar la retención de clientes y optimizar la rentabilidad del negocio. La siguiente sección abordará precisamente este aspecto, analizando distintas estrategias de fidelización y promoción basadas en los hallazgos del modelo

6. Estrategias de Fidelización y Promoción en Food Delivery

Los hallazgos del modelo han demostrado que la fijación de descuentos y comisiones influye en la rentabilidad y retención de clientes. En particular, se ha observado que las estrategias basadas en descuentos masivos no garantizan la fidelización a largo plazo y pueden erosionar los márgenes de beneficio. En esta sección, se analizan cuatro estrategias clave que pueden mejorar la retención de clientes y optimizar la rentabilidad en plataformas de *food delivery*, alineadas con los hallazgos del modelo y las tendencias del sector.

6.1. Personalización inteligente de descuentos

Si bien los descuentos pueden atraer clientes en el corto plazo, su impacto en la fidelización es limitado. Los datos muestran que los clientes que no reciben descuentos presentan una tasa de retención del 13.5 %, ligeramente superior al 9.7 % registrado entre quienes sí los reciben. Además, los descuentos en porcentaje tienden a generar mayores pérdidas en comparación con los descuentos fijos, ya que reducen desproporcionadamente los márgenes de beneficio en pedidos de alto valor.

Para abordar estas limitaciones, las plataformas pueden desarrollar modelos de descuentos dinámicos que ajusten las promociones en función de la rentabilidad esperada y del comportamiento de compra del usuario. En lugar de aplicar descuentos generalizados, una estrategia más eficiente sería ofrecer incentivos personalizados únicamente a clientes con alto riesgo de abandono o que han demostrado un patrón de compras recurrente.

Este enfoque se alinea con lo señalado en la Entrevista con un Senior Commercial Manager de Uber Eats (ver Anexo 2), donde se destaca la importancia de utilizar inteligencia artificial para segmentar clientes según su probabilidad de retorno y optimizar las promociones en función de su perfil de consumo.

Como alternativa complementaria, las plataformas pueden experimentar con estrategias de precios inteligentes. En este esquema, los descuentos podrían reducirse progresivamente para los clientes que ya han mostrado fidelidad, mientras que los nuevos usuarios recibirían incentivos ajustados a su comportamiento inicial. De este modo, se optimizaría el uso de promociones sin comprometer la rentabilidad de manera indiscriminada.

6.2. Programas de fidelización y beneficios exclusivos

Más allá de los descuentos, los programas de fidelización han demostrado ser una estrategia más efectiva para mejorar la recurrencia de los clientes sin comprometer la rentabilidad. Estos programas pueden estructurarse a través de suscripciones con beneficios exclusivos o sistemas de recompensas basados en el historial de compras del usuario, generando incentivos que fomentan el uso continuo de la plataforma.

Una opción es implementar modelos de suscripción, donde los clientes pagan una tarifa mensual para acceder a ventajas como envíos gratuitos, promociones exclusivas o acceso prioritario a ciertos restaurantes y productos populares. Según la Entrevista con un ex-Head of Marketing de Uber Eats en España (ver Anexo 1), programas como Uber One y Glovo Prime han sido clave para aumentar la recurrencia de los clientes, ya que generan valor adicional sin necesidad de aplicar descuentos constantes.

Otra alternativa es el desarrollo de programas de puntos o recompensas, en los cuales los clientes acumulan puntos por cada pedido realizado y pueden canjearlos por productos gratuitos o mejoras en el servicio. Este tipo de estrategia no solo incentiva la repetición de compra, sino que también refuerza el sentido de exclusividad y pertenencia, favoreciendo la lealtad a la plataforma.

6.3. Exclusividad de la oferta y diferenciación

Las plataformas de *food delivery* pueden fortalecer su propuesta de valor a través de estrategias de exclusividad con ciertos restaurantes o categorías de productos. En lugar de competir únicamente en precio, la diferenciación mediante acuerdos estratégicos permite ofrecer opciones exclusivas que generan mayor fidelización sin comprometer la rentabilidad.

Una de las estrategias más efectivas es la negociación de acuerdos con restaurantes reconocidos para que ciertos menús o productos solo estén disponibles en una plataforma específica. Este enfoque no solo incrementa la demanda de manera orgánica, sino que también mejora la percepción de valor de la plataforma, reduciendo la necesidad de recurrir a descuentos.

Según la Entrevista con un ex-Head de Marketing de Uber Eats (ver Anexo 1), la exclusividad de restaurantes ha sido utilizada en el pasado para aumentar el tráfico sin aplicar promociones agresivas. Un ejemplo relevante fue el acuerdo entre Glovo y McDonald's en ciertos mercados, que permitió atraer clientes sin necesidad de descuentos adicionales.

Además de los acuerdos con restaurantes, las plataformas pueden explorar la creación de categorías de productos premium o menús exclusivos, en colaboración con establecimientos

estratégicos. Esta iniciativa permitiría a los clientes acceder a experiencias diferenciadas dentro de la misma aplicación, reforzando su lealtad a la plataforma y aumentando el valor percibido del servicio.

6.4. Inteligencia artificial para la optimización de la retención

El uso de inteligencia artificial se ha consolidado como un factor clave en la optimización de estrategias de fidelización en plataformas de *food delivery*. Su capacidad para anticiparse a las necesidades de los clientes y ajustar los servicios de manera proactiva permite mejorar la experiencia del usuario sin depender de descuentos agresivos.

Una de sus principales aplicaciones es la implementación de sistemas de predicción de demanda, que optimizan los tiempos de entrega y ajustan las tarifas en función de la saturación del servicio. Esto no solo mejora la eficiencia operativa, sino que también reduce la insatisfacción del cliente, un factor determinante en la retención. Según la Entrevista con un Senior Commercial Manager de Uber Eats (ver Anexo 2), la optimización dinámica de tarifas de entrega en función de la demanda ha resultado ser una estrategia efectiva para equilibrar la carga operativa y evitar la pérdida de clientes debido a tiempos de espera prolongados.

Otra aplicación de la IA es el análisis del comportamiento de compra de los usuarios, que permite personalizar la oferta dentro de la aplicación. Esto puede traducirse en recomendaciones automatizadas de restaurantes, ofertas limitadas basadas en preferencias previas o recordatorios de pedidos frecuentes, mejorando así la relevancia de las promociones y aumentando la conversión de clientes.

Para maximizar el impacto de estas estrategias, se recomienda que las plataformas desarrollen modelos predictivos capaces de identificar patrones de abandono y activar estrategias preventivas. Entre ellas, los descuentos selectivos y las mejoras en la experiencia del usuario pueden ser herramientas clave para reducir la pérdida de clientes y fomentar su fidelización a largo plazo.

6.5. Contraste entre modelos y expertos del sector

Para reforzar la conexión entre el análisis cuantitativo y cualitativo, la Tabla 6 resume las principales ideas extraídas de entrevistas con expertos del sector, destacando cómo validan o matizan los resultados obtenidos en este estudio.

Tabla 6. Validación de estrategias de fidelización: opiniones de expertos en food delivery

Experto	Ideas Clave	Validación del Modelo
Ex-Head of Marketing (Uber Eats España)	<ul style="list-style-type: none"> Programas de fidelización como Uber One son clave para la retención. Promociones con recompensas (ej. producto gratis tras X pedidos) funcionan mejor que descuentos directos. Exclusividad de restaurantes en la plataforma aumenta la demanda sin necesidad de descuentos 	<ul style="list-style-type: none"> Confirma que los programas de suscripción incentivan el uso recurrente sin reducir márgenes. Reafirma que los descuentos generalizados no generan lealtad, pero los incentivos sí. Coincide con el hallazgo de que ofertas exclusivas son más rentables que promociones abiertas.
Senior Commercial Manager (Uber Eats España)	<ul style="list-style-type: none"> Descuentos personalizados según comportamiento del usuario mejoran la retención. Métricas clave: tasa de conversión, valor promedio del pedido y ROI IA optimiza precios dinámicos y rutas de entrega para mejorar rentabilidad. 	<ul style="list-style-type: none"> Valida el uso de modelos predictivos para ajustar promociones según riesgo de abandono (churn). Confirma que la optimización de descuentos debe basarse en datos financieros para evitar pérdidas. Apoya la idea de que la retención no depende solo de descuentos, sino de la experiencia del usuario.

6.6. Conclusiones y aplicabilidad

Los hallazgos de este estudio confirman que las plataformas de *food delivery* deben evolucionar más allá de los descuentos tradicionales para fidelizar clientes de manera sostenible.

- Las estrategias de descuentos deben estar basadas en datos y dirigidas a segmentos específicos, evitando promociones generalizadas que reduzcan la rentabilidad.
- Los programas de suscripción y recompensas generan mayor retención sin afectar los márgenes de ganancia.
- La exclusividad de restaurantes dentro de la plataforma es una estrategia efectiva para atraer clientes sin depender de descuentos agresivos.
- La inteligencia artificial permite optimizar la experiencia del usuario y mejorar la fidelización mediante estrategias de personalización y predicción de demanda.

Adoptar estos enfoques permitirá a las plataformas maximizar la rentabilidad y mejorar la fidelización de clientes en un mercado altamente competitivo.

Para consolidar las principales conclusiones de este estudio, la Tabla 7 presenta un resumen de los hallazgos clave en relación con las estrategias de fidelización y su impacto en la rentabilidad de las plataformas de *food delivery*. Este esquema facilita la identificación de los enfoques más efectivos para mejorar la retención de clientes sin comprometer los márgenes de beneficio.

Tabla 7. Síntesis de estrategias y aplicabilidad en *food delivery*

Conclusión Clave	Implicaciones para las Plataformas	Relevancia
Los descuentos masivos no garantizan la fidelización y pueden reducir la rentabilidad.	Se deben implementar descuentos personalizados, aplicados únicamente a clientes con alto riesgo de abandono.	Alta factibilidad y alto impacto (puede aplicarse rápidamente con segmentación básica y mejora sustancial en márgenes)
Los programas de suscripción generan mayor recurrencia sin afectar márgenes.	Modelos como Uber One o Glovo Prime pueden replicarse con beneficios exclusivos que fomenten la lealtad sin depender de descuentos constantes.	Alto impacto, pero requiere inversión y escala
La exclusividad de restaurantes fortalece la diferenciación sin necesidad de promociones agresivas.	Establecer acuerdos estratégicos con restaurantes clave puede atraer clientes y mejorar la percepción de valor de la plataforma.	Impacto medio-alto, factibilidad limitada (requiere negociación bilateral y diferenciación local)
La inteligencia artificial permite optimizar estrategias de fidelización y rentabilidad.	Aplicar modelos predictivos para personalizar promociones, ajustar tarifas de entrega y mejorar la experiencia del usuario sin recurrir a estrategias generalizadas.	Alta factibilidad y alto impacto (especialmente si ya se cuenta con recursos analíticos internos)
El análisis de datos es clave para ajustar dinámicamente comisiones y descuentos.	Integrar técnicas de <i>machine learning</i> para definir esquemas dinámicos de comisiones y descuentos según el perfil del usuario y el margen del pedido.	Alta factibilidad técnica, impacto alto a medio plazo (requiere alineación interna y cambios en políticas comerciales)

7. Conclusiones y Trabajo Futuro

Este capítulo reúne los hallazgos principales y ofrece una visión integral sobre la aplicación de estrategias de fidelización y su repercusión en la rentabilidad de las plataformas de *food delivery*. Además, se discuten las limitaciones del estudio y se proponen posibles líneas de investigación que podrían complementar o ampliar los resultados obtenidos.

7.1. Limitaciones del estudio

Si bien se ha aplicado una metodología sólida y un análisis riguroso, este trabajo presenta ciertas limitaciones que conviene tomar en cuenta al interpretar los resultados:

- 1. Dependencia de datos transaccionales específicos:** La base de datos analizada proviene de una única plataforma de *food delivery* en la India, lo que puede restringir la generalización de los resultados a otros mercados con diferentes dinámicas competitivas y estructuras de costes.
- 2. Sesgo geográfico y cultural:** Los hábitos de consumo y la infraestructura digital varían entre países, de modo que los hallazgos no necesariamente reflejan la realidad de otros contextos geográficos. Factores como preferencias gastronómicas o poder adquisitivo podrían modificar la eficacia de las estrategias de fidelización.
- 3. Limitaciones en las variables disponibles:** El estudio no incluye costes logísticos internos ni métricas como la percepción del servicio o el abandono de clientes. Esto puede limitar la visión global del impacto financiero de la fidelización y omitir elementos clave para la experiencia del usuario.
- 4. Horizonte temporal reducido:** El conjunto de datos abarca únicamente 37 días, comprendidos entre enero y febrero de 2024, lo que dificulta la evaluación de la sostenibilidad de las estrategias de fidelización a largo plazo. Un periodo de análisis más extenso permitiría observar con mayor precisión la evolución de la retención y la rentabilidad en escenarios variables.
- 5. Exclusión de factores cualitativos:** La investigación se basa principalmente en datos cuantitativos. Aspectos como la reputación de marca, la experiencia subjetiva del cliente o las motivaciones de compra no han sido contemplados de forma exhaustiva, lo que podría incidir en la fidelización y el rendimiento financiero de la plataforma.

7.2.Recomendaciones y líneas de investigación futura

El presente estudio ha permitido evidenciar que las plataformas de *food delivery* afrontan el reto de equilibrar la rentabilidad y la fidelización de clientes en un entorno altamente competitivo. Los resultados confirman, en línea con Chen et al. (2022) y Van Veldhoven et al. (2021), que la fijación de comisiones a los restaurantes y de descuentos afecta de manera decisiva la sostenibilidad financiera de estas plataformas. En particular, se observó que las promociones agresivas, especialmente los descuentos en porcentaje, no incrementan de forma significativa la fidelización del cliente y, en ciertos casos, generan grandes pérdidas. Este hallazgo coincide con lo planteado por Bawornmongkolsak (2021), quien subraya la importancia de precios competitivos y una menor dependencia de ofertas masivas para obtener mejores resultados a largo

plazo. Asimismo, las altas comisiones fijas para pedidos de bajo importe han derivado en márgenes negativos para determinados restaurantes, lo que resalta la complejidad de los esquemas de monetización y la necesidad de mayor transparencia en la estructura de costes.

La construcción de modelos predictivos y explicativos con técnicas de *machine learning* (Random Forest, XGBoost, LightGBM y Redes Neuronales) revela que la tasa de comisión y la tasa de descuento se explican en gran medida por variables como *Order Value (EUR)* y *Profit Margin (%)*. Estos hallazgos sugieren que un ajuste dinámico de comisiones y descuentos — basado en el valor del pedido, la rentabilidad estimada y la probabilidad de recompra— puede mejorar la sostenibilidad financiera de la plataforma sin sacrificar la experiencia del usuario. No obstante, la capacidad predictiva para la *Discount Rate (%)* ha resultado moderada, lo que indica la posible intervención de factores externos no contemplados (por ejemplo, acuerdos puntuales con restaurantes o las cambiantes preferencias del consumidor).

En el plano práctico, se recomienda que las plataformas adopten estrategias más segmentadas y personalizadas, por ejemplo, ofrecer descuentos únicamente a los segmentos con mayor probabilidad de abandono, al tiempo que se revisa el esquema de comisiones para mejorar la confianza de los restaurantes. Alternativas como programas de suscripción (Uber One, Glovo Prime) o sistemas de recompensas por puntos también se perfilan como vías efectivas para fomentar recurrencia sin recurrir de manera desmedida a promociones que erosionen los márgenes de beneficio.

De cara al futuro, integrar variables adicionales sobre el comportamiento del usuario (frecuencia de uso, historial de compras, preferencias culinarias) y factores contextuales (estacionalidad, promociones cruzadas con otros servicios) podría afinar la precisión de los modelos predictivos y reforzar la toma de decisiones estratégicas. Asimismo, sería pertinente profundizar en el papel de la inteligencia artificial y la optimización de precios para proponer mecanismos de retención menos dependientes de descuentos agresivos. Finalmente, resultaría útil contrastar estos resultados con los de otras plataformas y mercados geográficos, a fin de verificar hasta qué punto las conclusiones conservan su validez en contextos regulatorios y culturales diversos.

Más allá del plano teórico, estos resultados no solo ofrecen implicaciones estratégicas para grandes plataformas consolidadas, sino que también resultan especialmente útiles para actores emergentes del sector. Startups de *food delivery* pueden emplear estas conclusiones para diseñar modelos de negocio más sostenibles desde su fase inicial, evitando dependencias estructurales de promociones masivas. Asimismo, los diseñadores de experiencia de usuario (UX) pueden apoyarse en los hallazgos para crear recorridos más personalizados y eficientes dentro de las aplicaciones, optimizando la retención desde la interfaz. Finalmente, los responsables de

pricing, analistas de datos y gestores de producto pueden encontrar en este marco analítico una base sólida para la toma de decisiones basada en evidencia, adaptable a distintos entornos competitivos y perfiles de usuario.

8. Bibliografía

Addai, E., Torres, D. F. M., Abdul-Hamid, Z., Mezue, M. N., & Asamoah, J. K. K. (2024).

Modelling the dynamics of online food delivery services on the spread of food-borne diseases (No. arXiv:2406.15438). arXiv. <https://doi.org/10.1007/s40808-024-02046-8>

Alvarez-Palau, E. J., Calvet-Liñán, L., Viu-Roig, M., Gandouz, M., & Juan, A. A. (2022).

Economic profitability of last-mile food delivery services: Lessons from Barcelona. *Research in Transportation Business & Management*, 45, Article 100659. <https://doi.org/10.1016/j.rtbm.2021.100659>

Amankwah-Amoah, J., Khan, Z., Wood, G., & Knight, G. (2021). COVID-19 and digitalization:

The great acceleration. *Journal of Business Research*, 136, 602-611. <https://doi.org/10.1016/j.jbusres.2021.08.011>

Arli, D., van Esch, P., & Weaven, S. (2024). The Impact of SERVQUAL on Consumers'

Satisfaction, Loyalty, and Intention to Use Online Food Delivery Services. *Journal of Promotion Management*, 30(7), 1159-1188. <https://doi.org/10.1080/10496491.2024.2372858>

Bawornmongkolsak, R. (2021). *A Study of Factors Affecting Customer Loyalty of Healthy*

Delivery Food [Master's thesis, Thammasat University]. https://ethesisarchive.library.tu.ac.th/thesis/2020/TU_2020_6202040462_13818_13778.pdf

Caridi, M. (2021). *Digital affordance: Analysis in the case of food delivery* [Master's thesis,

Politecnico di Torino]. <https://webthesis.biblio.polito.it/17740/>

Chen, M., Hu, M., & Wang, J. (2022). Food Delivery Service and Restaurant: Friend or Foe?

Management Science, 68(9), 6539-6551. <https://doi.org/10.1287/mnsc.2021.4245>

- Curry, D. (2025, enero 22). *Food Delivery App Revenue and Usage Statistics (2025)*. Business of Apps. <https://www.businessofapps.com/data/food-delivery-app-market/>
- Delgado, M. M. (2023). *Predictive Customer Lifetime value modeling: Improving customer engagement and business performance* [Master's thesis, Universidad Torcuato Di Tella]. <https://repositorio.utdt.edu/handle/20.500.13098/12029>
- Donsuchit, T., & Nuangjamnong, C. (2022). Determinants of Influencing Customer Loyalty and Repurchase Intention toward Mobile Application Food Delivery Service in Bangkok. *International Research E-Journal on Business and Economics*, 7(1), Article 1.
- DoorDash. (2023, mayo 2). *¿Qué precios y productos de DoorDash son adecuados para ti?* DoorDash para tiendas. <https://merchants.doordash.com/es-us/blog/doordash-pricing-products>
- Feldman, P., Frazelle, A. E., & Swinney, R. (2023). Managing Relationships Between Restaurants and Food Delivery Platforms: Conflict, Contracts, and Coordination. *Management Science*, 69(2), 812-823. <https://doi.org/10.1287/mnsc.2022.4390>
- Food Pac. (2024, abril 12). *¿Cuánto Cobra Glovo A Los Restaurantes?* Food Pac Service. <https://foodpacservic.com/centro-de-conocimiento/cuanto-cobra-glovo-a-los-restaurantes-y-como-se-hace/>
- Garay Freire, G. D., & Álvarez Reyes, G. M. (2024). Transformación digital en la logística: Un análisis bibliográfico de la influencia de las tecnologías de la información en la industria 4.0 y el desarrollo web. *Imaginario Social*, 7(1), 132-155. <https://doi.org/10.59155/is.v7i1.154>
- Härmand, K. (2021). Digitalisation before and after the Covid-19 crisis. *ERA Forum*, 22(1), 39-50. <https://doi.org/10.1007/s12027-021-00656-8>
- Helgesen, Ø. (2000). *Are loyal customers profitable? Customer satisfaction, customer loyalty and customer profitability at the individual level* (Working Paper No. 2000:1). SNF / Centre for Fisheries Economics. <https://openaccess.nhh.no/nhh-xmlui/handle/11250/165896>

- Islam, A. K. M., Mäntymäki, M., & Bhattacharjee, A. (2017). Towards a Decomposed Expectation Confirmation Model of IT Continuance: The Role of Usability. *Communications of the Association for Information Systems*, 40(23), 502-523. <https://doi.org/10.17705/1CAIS.04023>
- Kovalev, V., Novikova, K., & Antineskul, E. (2022). Efficiency of customer loyalty programmes in the food retail industry. *Journal of New Economy*, 23(4), 121-136. <https://doi.org/10.29141/2658-5081-2022-23-4-6>
- Kumar, V., & Petersen, J. A. (2005). Using a customer-Level marketing strategy to enhance firm performance: A review of theoretical and empirical evidence. *Journal of the Academy of Marketing Science*, 33(4), 504-519. <https://doi.org/10.1177/0092070305275857>
- Lee, S. (Olivia), & Han, H. (2022). Food delivery application quality in customer brand loyalty formation: Identifying its antecedent and outcomes. *International Journal of Hospitality Management*, 107, 103292. <https://doi.org/10.1016/j.ijhm.2022.103292>
- Lempert, P. (2023, febrero 17). *The Future Of Food Delivery Depends On Human Emotions: Not Speed*. Forbes. <https://www.forbes.com/sites/phillempert/2023/02/17/the-future-of-food-delivery-depends-on-human-emotions-not-speed/>
- Leuschner, R., Lambert, D. M., & Knemeyer, A. M. (2012). Logistics Performance, Customer Satisfaction, and Share of Business: A Comparison of Primary and Secondary Suppliers. *Journal of Business Logistics*, 33(3), 210-226. <https://doi.org/10.1111/j.2158-1592.2012.01053.x>
- Li, Z., & Wang, G. (2024). On-Demand Delivery Platforms and Restaurant Sales. *Management Science*. <https://doi.org/10.1287/mnsc.2021.01010>
- Limsarun, T., Navavongsathian, A., Vongchavalitkul, B., & Damrongpong, N. (2021). Factors Affecting Consumer's Loyalty in Food Delivery Application Service in Thailand. *The Journal of Asian Finance, Economics and Business*, 8(2), 1025-1032. <https://doi.org/10.13106/JAFEB.2021.VOL8.NO2.1025>

- Mateo, A. (2019, enero 22). *Horarios indios versus horarios españoles*. Historias Malasa. <http://www.historiasmasala.com/horarios-indios-versus-horarios-espanoles/>
- Ministerio de Asuntos Económicos y Transformación Digital. (2021). *Guía práctica de introducción al Análisis Exploratorio de Datos* [Guía Técnica]. Red.es. https://datos.gob.es/sites/default/files/doc/file/analisis_exploratorio_de_datos_2021.pdf
- Naranjo-Armijo, F. G., & Almeida-Blacio, J. H. (2024). Transformación Digital y Sostenibilidad: Un Nuevo Paradigma en la Administración de Empresas. *Código Científico Revista de Investigación*, 5(E3), Article E3. <https://doi.org/10.55813/gaea/ccri/v5/nE3/323>
- Niu, B., Li, Q., Mu, Z., Chen, L., & Ji, P. (2021). Platform logistics or self-logistics? Restaurants' cooperation with online food-delivery platform considering profitability and sustainability. *International Journal of Production Economics*, 234, 108064. <https://doi.org/10.1016/j.ijpe.2021.108064>
- Oliver, R. L. (1999). Whence Consumer Loyalty? *Journal of Marketing*, 63(Special Issue), 33-44. <https://doi.org/10.2307/1252099>
- Panjaitan, R. (2021). The Role of Digital Loyalty Program towards Customer Loyalty through a Measure of Satisfaction. *The Winners*, 22(2), 163-171. <https://doi.org/10.21512/tw.v22i2.7082>
- Paramasivam, P. (2024, noviembre 19). India's Zomato expects food delivery business to grow 30% annually over 5 years, exec says. *Reuters*. <https://www.reuters.com/business/retail-consumer/indias-zomato-expects-food-delivery-business-grow-30-annually-over-5-years-exec-2024-11-19/>
- Raj, M., Sundararajan, A., & You, C. (2023). *COVID-19 and Digital Resilience: Evidence from Uber Eats* (No. arXiv:2006.07204). arXiv. <https://doi.org/10.48550/arXiv.2006.07204>
- Renaldi, A., Hati, S. R. H., Ghazali, E., Sumarwan, U., & Ramayah, T. (2024). The determinants of customer loyalty in the sharing economy: A study of the largest local food delivery

- apps in Indonesia. *Cogent Business & Management*, 11(1), 2364055.
<https://doi.org/10.1080/23311975.2024.2364055>
- Ruslan, A. F., Shukur, S. A. M., binti Anwar, N. A., & bin Ahmad, M. F. (2024). Customer Satisfaction Towards Food Delivery Services in Selangor. *Information Management and Business Review*, 16(3S(I)a), 1034-1039. [https://doi.org/10.22610/imbr.v16i3S\(I\)a.4192](https://doi.org/10.22610/imbr.v16i3S(I)a.4192)
- Sahoo, T., Sonwani, S., Pandya, R., & Rane, N. (2024). Advanced Food Delivery: Efficiency, Safety, and Satisfaction Innovations. *2024 2nd World Conference on Communication & Computing (WCONF)*, 1-6. <https://doi.org/10.1109/WCONF61366.2024.10692311>
- Scarlat, C., Stănciulescu, G. D., & Panduru, D. A. (2022). COVID-19 Pandemic as Accelerator: Opportunity for Digital Acceleration. *Journal of Internet and E-Business Studies*, 1-14.
<https://doi.org/10.5171/2022.296375>
- Sharma, S., Devi, K., Naidu, S., Greig, T., Singh, G., & Slack, N. (2023). From brick and mortar to click and order: Consumers' online food delivery service perceptions post-pandemic. *British Food Journal*, 125(11), 4143-4162. <https://doi.org/10.1108/BFJ-04-2023-0351>
- Shi, Z., & Shang, H. (2020). A Review on Quality of Service and SERVQUAL Model. In F. F.-H. Nah & K. Siau (Eds.), *HCI in Business, Government and Organizations* (pp. 188-204). Springer International Publishing. https://doi.org/10.1007/978-3-030-50341-3_15
- Siddiqi, K. O., Rahman, J., Tanchangya, T., Rahman, H., Esquivias, M. A., & Rahman, Md. H. (2024). Investigating the factors influencing customer loyalty and the mediating effect of customer satisfaction in online food delivery services: Empirical evidence from an emerging market. *Cogent Business & Management*, 11(1), 2431188.
<https://doi.org/10.1080/23311975.2024.2431188>
- StartupStory. (2023, marzo 3). *Zomato urges restaurants to raise advertising expenses on its platform and take responsibility for refunds*. StartupStory Media.
<https://startupstorymedia.com/insights-zomato-urges-restaurants-to-raise-advertising-expenses-on-its-platform-and-take-responsibility-for-refunds/>

- Uber. (2025). *Cómo administrar los reembolsos por pedidos incorrectos o incompletos*. Uber Help Center. <https://help.uber.com/es/merchants-and-restaurants/article/cómo-administrar-los-reembolsos-por-pedidos-incorrectos-o-incompletos?nodeId=9aa57e9b-8bbf-4aa7-91d6-96ca77682dd2>
- Uber Eats. (2025). *Precios que se adaptan a tu negocio*. Uber Eats for Merchants. <https://merchants.ubereats.com/us/es/pricing/>
- Van Veldhoven, Z., Aerts, P., Ausloos, S. L., Bernaerts, J., & Vanthienen, J. (2021). The Impact of Online Delivery Services on the Financial Performance of Restaurants. *2021 7th International Conference on Information Management (ICIM)*, 13-17. <https://doi.org/10.1109/ICIM52229.2021.9417153>
- Wiki User. (2022, marzo 11). *What time do people have breakfast lunch and dinner in India?* Answers. https://www.answers.com/movies-and-television/What_time_do_people_have_breakfast_lunch_and_dinner_in_India#:~:text=Breakfast%20is%20anywhere%20between%20,10am
- Yuan, Y., & Lai, Z. (2023). *Brand Loyalty in the Context of Digital Food Retail: Understanding customer behaviour of meal kit delivery services towards brand loyalty: A focus on HelloFresh* [Master's thesis]. Jönköping University.
- Zhang, Y., & Ha, H.-Y. (2024). The evolution of consumer restaurant selection: Changes in restaurant and food delivery application attributes over time. *Journal of Business Research*, 170, 114323. <https://doi.org/10.1016/j.jbusres.2023.114323>

9. Anexos

Con el objetivo de facilitar la comprensión y el seguimiento de los testimonios recogidos, a continuación se presenta la Tabla 8, que resume de forma estructurada los perfiles entrevistados, sus cargos y los principales *insights* derivados de cada conversación.

Tabla 8. Cuadro resumen de entrevistas

Nombre Clave	Cargo	Insights Clave
Entrevistado A	Ex-Head of Marketing de Uber Eats en España	<ul style="list-style-type: none">• Relevancia de suscripciones tipo Uber One- Promociones directas y exclusividad de restaurantes• Valor diferencial vía IA para precios y demanda
Entrevistado B	Senior Commercial Manager en Uber Eats España	<ul style="list-style-type: none">• Efectividad de Uber Eats Pass• Métricas clave: conversión, AOV, ROI, retención- IA para personalización, logística y predicción

Tras el cuadro resumen, se desarrolla en detalle el contenido de cada entrevista, comenzando por la realizada al ex-Head of Marketing de Uber Eats en España.

Anexo 1. Entrevista con ex-Head of Marketing de Uber Eats en España

- Perfil: Profesional con trayectoria en compañías internacionales de marketing y tecnología.
- Formato de la entrevista: Videollamada en Google Meet, realizada el 11 de noviembre de 2024 (15 minutos).
- Guion de Preguntas:
 1. *¿Cuáles consideras que han sido las claves en la estrategia de fidelización y retención de usuarios en el sector del delivery?*
 2. *Hablando de promociones específicas para retener usuarios, ¿puedes compartir algún ejemplo exitoso aplicado en Uber Eats?*
 3. *Desde tu perspectiva, ¿cuáles son las estrategias principales para ofrecer una propuesta de valor sólida en el delivery?*
 4. *¿Cómo ves el papel de la inteligencia artificial y el manejo de datos para mejorar la rentabilidad y la retención de clientes?*
- Contenido de las respuestas (extracto):
 1. *“Los programas de lealtad son uno de los pilares principales. En nuestro caso, Uber One —y en competencia, algo similar con Glovo Prime— ofrecen ventajas claras, como descuentos o exención de tarifas de entrega, que fomentan el uso frecuente de la plataforma. Este tipo de suscripciones, junto con la posibilidad de realizar ‘cross-selling’ —por ejemplo, en Uber Eats, el usuario también puede solicitar un coche,*

mientras que en Glovo, además de comida, se puede comprar y enviar productos— incrementan enormemente la propuesta de valor de la marca.”

2. *“En su momento, tuvimos restaurantes dentro de Uber Eats con promociones del tipo: si realizabas más de 10 pedidos, recibías un producto gratis. Ese tipo de recompensas directas ayuda a que el usuario adopte hábitos de consumo dentro de la plataforma. Otra estrategia es disponer de restaurantes exclusivos; hubo un periodo en el que, por ejemplo, McDonald’s solo estaba disponible en Glovo, lo cual incrementaba mucho su atractivo y tráfico. Si consigues que un restaurante popular sea exclusivo en tu plataforma, mejoras significativamente tu propuesta de valor.”*
3. *“En mi experiencia, destaco tres:*
 - I. *Promociones y ofertas: como 3x2 o regalos de comida para generar el hábito de uso continuo en el cliente.*
 - II. *Excelencia operacional: ser más rápido y eficiente que la competencia. En mi etapa, considerábamos que Uber Eats ofrecía entregas más ágiles que otros, y eso es un factor determinante para la satisfacción del usuario.*
 - III. *Exclusividad de restaurantes: asegurar que ciertos establecimientos solo estén disponibles en tu plataforma (o que al menos tengan ciertas ofertas únicas) marca una gran diferencia.”*
4. *“La IA resulta esencial para optimizar varios aspectos del negocio. Por ejemplo, la tarifa de entrega (delivery fee) puede ajustarse dinámicamente según la demanda. Cuando se prevén picos de pedidos, el sistema eleva el precio para regular la saturación y, a su vez, aumentar la rentabilidad. Del mismo modo, la IA permite predecir cuándo habrá mayor demanda y ajustar la operativa —repartidores, ofertas, etc.— en consecuencia. Además, es útil para realizar predicciones de catálogo, definir mejor la propuesta de valor y descubrir patrones de consumo en ciertos restaurantes o zonas, lo que acaba impactando directamente en la experiencia de los usuarios y en la eficiencia de la plataforma.”*

Anexo 2. Entrevista con Senior Commercial Manager en Uber Eats España

- Perfil: Experiencia en ventas y marketing en el sector de medios y plataformas digitales.
- Formato de la entrevista: Videollamada en Google Meet, realizada el 17 de febrero de 2025 (15 minutos).
- Guion de Preguntas:

1. *¿Cuál ha sido la estrategia de promoción más efectiva empleada por Uber Eats para fidelizar a los clientes y cómo afecta dicha estrategia a la rentabilidad de la empresa?*
 2. *¿Qué indicadores se emplean para evaluar la efectividad de dichas promociones y asegurar su viabilidad financiera?*
 3. *¿Cómo consideras que la inteligencia artificial está influyendo en la retención de clientes y la rentabilidad de Uber Eats?*
- Contenido de las respuestas (extracto)
 1. *“Una de las estrategias más efectivas de Uber Eats para fidelizar clientes ha sido el uso de programas de lealtad y suscripciones, como Uber Eats Pass. Este programa ofrece beneficios como entregas gratuitas y descuentos exclusivos, incentivando a los usuarios a realizar pedidos recurrentes. Además, los descuentos personalizados y las promociones dirigidas han sido clave para mantener a los clientes comprometidos. Estas iniciativas no solo aumentan la retención, sino que también generan ingresos recurrentes al fomentar pedidos frecuentes, lo que contribuye directamente a la sostenibilidad del modelo de negocio.”*
 2. *“Uber Eats utiliza métricas clave para medir el éxito de sus promociones, como:*
 - *Tasa de conversión: porcentaje de usuarios que realizan un pedido tras interactuar con una promoción.*
 - *Valor promedio del pedido (AOV): para evaluar si las promociones aumentan el gasto por pedido.*
 - *Retención de clientes: porcentaje de usuarios que regresan tras aprovechar una promoción.*
 - *Retorno sobre la inversión (ROI): ingresos generados en relación con el costo de la promoción.**Estas métricas permiten optimizar campañas futuras y garantizar su viabilidad financiera.”*
 3. *“La evolución de la inteligencia artificial tiene un impacto significativo en Uber Eats, especialmente en áreas como personalización y eficiencia operativa. La IA permite ofrecer recomendaciones personalizadas basadas en el historial del cliente, optimizar rutas de entrega para reducir tiempos y costes, y predecir patrones de demanda para ajustar promociones estratégicamente. Esto no solo mejora la experiencia del usuario, aumentando la retención, sino que también reduce costes operativos, impulsando la rentabilidad general.”*

10. Declaración de Uso de Herramientas de IAG

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Jaime Ramón Sol Arce, estudiante de E2 + Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Estrategias de Fidelización en Apps de Food Delivery: Impacto en la rentabilidad y retención de clientes", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
10. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
11. **Generador de datos sintéticos de prueba:** Para la creación de conjuntos de datos ficticios.
12. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
13. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
14. **Generador de encuestas:** Para diseñar cuestionarios preliminares.
15. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 08/04/2025

Firma: Jaime Ramón Sol Arce