

Optimización De Horarios De Contacto Con Clientes Utilizando Un Modelo De Clasificación Predictivo: Caso Empresa de Cobranza ABC

Optimization of Customer Contact Schedules Using a Predictive Classification Model: ABC Collection Company Case Study

Otimização das horas de contacto com o cliente utilizando um modelo de ordenação preditivo: o estudo de caso da empresa de cobranças ABC

Carrillo-Tixe, Vicente Anibal
Escuela Superior Politécnica de Chimborazo
anibal.carrillo@esPOCH.edu.ec
<https://orcid.org/0009-0001-1054-1025>



Logroño-Naranjo, Santiago Israel
Escuela Superior Politécnica de Chimborazo
israel.logronio@esPOCH.edu.ec
<https://orcid.org/0000-0002-1205-3017>



DOI / URL: <https://doi.org/10.55813/gaea/ccri/v6/n1/952>

Como citar:

Carrillo-Tixe, V. A., & Logroño-Naranjo, S. I. (2025). Optimización De Horarios De Contacto Con Clientes Utilizando Un Modelo De Clasificación Predictivo: Caso Empresa de Cobranza ABC. *Código Científico Revista De Investigación*, 6(1), 1468–1493. <https://doi.org/10.55813/gaea/ccri/v6/n1/952>

Recibido: 11/06/2025

Aceptado: 27/06/2025

Publicado: 30/06/2025

Resumen

Este estudio presenta la implementación de un modelo de tipo predictivo el cual será empleado para la clasificación, apoyado en técnicas de aprendizaje automático, para optimizar los horarios de contacto telefónico con clientes en una empresa dedicada a la gestión de cobranzas. A partir del análisis de más de 3.5 millones de registros históricos, se identificaron patrones de comportamiento que permiten establecer los momentos del día con mayor probabilidad de contacto efectivo. Los resultados muestran que los rangos horarios de 9:00 a 12:59 (H2) y de 13:00 a 15:59 (H3) presentaron tasas de efectividad del 36.5 % y 25.2 %, respectivamente, mientras que el horario nocturno (19:00 a 23:59) apenas alcanzó un 5.9 %. Con la meta de mejorar considerablemente la eficiencia operativa del call center, se utilizaron los modelos Random Forest y Gradient Boosting, obteniendo una exactitud del 82.23 % y 82.22 %, respectivamente. La metodología CRISP-DM guió el desarrollo del proceso analítico, desde la comprensión del negocio hasta el despliegue del modelo en el sistema de gestión de llamadas de la empresa. El modelo Random Forest permitió además el etiquetado inteligente de los números telefónicos con su mejor rango horario, facilitando decisiones informadas y personalizadas por parte de los gestores. Este enfoque contribuye notablemente a la inteligencia artificial aplicada a procesos empresariales, proporcionando una herramienta robusta, escalable y adaptable para empresas que buscan maximizar su efectividad en la comunicación con clientes. La solución propuesta mejora no solo la tasa de contactabilidad, sino también la experiencia del usuario, al evitar llamadas en momentos inadecuados y asignar estratégicamente los recursos humanos y tecnológicos disponibles.

Palabras clave: efectividad de horario de contacto, gestión de cobranzas, inteligencia artificial, machine learning, modelo predictivo, optimización de horarios.

Abstract

This study presents the implementation of a predictive model which will be used for classification, supported by machine learning techniques, to optimize telephone contact schedules with customers in a company dedicated to collection management. From the analysis of more than 3.5 million historical records, behavioral patterns were identified that allow establishing the times of day with the highest probability of effective contact. The results show that the time ranges from 9:00 to 12:59 (H2) and from 13:00 to 15:59 (H3) presented effectiveness rates of 36.5% and 25.2%, respectively, while the night time (19:00 to 23:59) barely reached 5.9%. With the goal of considerably improving the operational efficiency of the call center, the Random Forest and Gradient Boosting models were used, obtaining an accuracy of 82.23% and 82.22%, respectively. The CRISP-DM methodology guided the development of the analytical process, from understanding the business to deploying the model in the company's call management system. The Random Forest model also allowed the intelligent labeling of telephone numbers with their best time range, facilitating informed and personalized decisions by managers. This approach contributes significantly to artificial intelligence applied to business processes, providing a robust, scalable and adaptable tool for companies looking to maximize their effectiveness in communicating with customers. The proposed solution improves not only the contactability rate, but also the user experience, by avoiding calls at inappropriate times and strategically allocating the available human and technological resources.

Keywords: effectiveness of contact hours, collection management, artificial intelligence, machine learning, predictive model, schedule optimization.

Resumo

Este estudo apresenta a implementação de um modelo preditivo que será utilizado para classificação, apoiado em técnicas de machine learning, para otimizar os agendamentos de contato telefônico com clientes em uma empresa dedicada à gestão de cobranças. A partir da análise de mais de 3,5 milhões de registros históricos, foram identificados padrões comportamentais que permitem estabelecer os horários do dia com maior probabilidade de contato efetivo. Os resultados mostram que os intervalos de horário das 9:00 às 12:59 (H2) e das 13:00 às 15:59 (H3) apresentaram taxas de efetividade de 36,5% e 25,2%, respectivamente, enquanto o período noturno (19:00 às 23:59) mal chegou a 5,9%.

Com o objetivo de melhorar consideravelmente a eficiência operacional do call center, foram utilizados os modelos Random Forest e Gradient Boosting, obtendo uma precisão de 82,23% e 82,22%, respectivamente. A metodologia CRISP-DM orientou o desenvolvimento do processo analítico, desde o entendimento do negócio até a implantação do modelo no sistema de gerenciamento de chamadas da empresa. O modelo Random Forest também permitiu a rotulagem inteligente de números de telefone com seu melhor intervalo de tempo, facilitando decisões informadas e personalizadas por parte dos gestores.

Essa abordagem contribui significativamente para a inteligência artificial aplicada aos processos de negócios, fornecendo uma ferramenta robusta, escalável e adaptável para empresas que buscam maximizar sua eficácia na comunicação com os clientes. A solução proposta melhora não só a taxa de contactabilidade, mas também a experiência do utilizador, evitando chamadas em horários inadequados e alocando estrategicamente os recursos humanos e tecnológicos disponíveis.

Palavras-chave: efetividade das horas de contato, gestão de coletas, inteligência artificial, aprendizado de máquina, modelo preditivo, otimização de cronograma.

Introducción

Esta investigación presenta un enfoque práctico y aplicado, orientado a resolver una problemática común en los centros de contacto o call centers, especialmente en el sector de cobranza: lograr identificar cuáles son los mejores momentos del día para contactar a los clientes, logrando que las llamadas telefónicas sean respondidas y, preferentemente, efectivas, es por esto que el objetivo principal es mejorar la eficiencia de las gestiones telefónicas, utilizando modelos predictivos basados en técnicas de aprendizaje automático, en este estudio, se aplican algoritmos como Random Forest (Breiman, 2001) y Gradient Boosting (Chen & Guestrin, 2016), los cuales son ampliamente reconocidos por su capacidad para modelar relaciones no lineales y ofrecer alta precisión en problemas de clasificación binaria.

La empresa objeto de estudio, denominada ABC, es una firma ecuatoriana dedicada a la cobranza, con operaciones en varias provincias del país y una cartera considerable de

clientes, esta empresa como muchas otras del sector financiero enfrenta desafíos constantes para lograr un contacto efectivo con sus usuarios, lo que repercute directamente en la tasa de recuperación

de cartera vencida, las llamadas se realizan, en muchos casos, sin una planificación estratégica lo que genera una baja tasa de respuesta, interacciones ineficientes, altos costos operativos y una percepción negativa por parte de los clientes en un contexto como el ecuatoriano, donde la cultura de pago es diversa y donde existe un segmento significativo de la población sin acceso constante a servicios financieros formales, resulta crucial optimizar los recursos disponibles para la gestión de cobranzas.

A nivel regional países como México, Colombia, y Perú han avanzado en la aplicación de modelos predictivos para segmentar clientes, priorizar gestiones y determinar horarios óptimos de contacto, lo cual ha demostrado beneficios operativos y financieros (Avdagić-Golub et al., 2020; Ramírez et al., 2021). Sin embargo, en Ecuador, la literatura académica sobre el uso de inteligencia artificial o modelos de machine learning en la industria de cobranzas aún es limitada ya que la mayoría de las empresas ecuatorianas continúan operando con metodologías tradicionales que no aprovechan el valor oculto en sus propios datos históricos y esta falta de estudios locales evidencia un vacío tanto a nivel investigativo como a nivel de implementación tecnológica, lo cual refuerza la pertinencia y novedad del presente estudio.

La problemática se enmarca debido a la inexistencia de sistemas inteligentes que permitan identificar no solo el mejor canal de contacto (llamada, mensaje, correo, etc.), sino también el momento del día más propicio para establecer comunicación con cada cliente, considerando su historial, tipo de deuda, comportamiento previo, entre otros factores, la

ausencia de este tipo de herramientas afecta negativamente la experiencia del cliente, incrementa el número de llamadas fallidas, y disminuye la eficiencia del personal operativo.

Frente a esta realidad, la presente investigación propone el diseño e implementación de un modelo predictivo que, a partir de datos históricos de gestión, permita etiquetar cada número telefónico con su rango horario más efectivo. Para ello, se emplea la metodología CRISP-DM, ampliamente reconocida en proyectos de ciencia de datos, estructurando el trabajo desde la comprensión del negocio hasta el despliegue del modelo en el entorno real.

De este modo, se busca responder a la siguiente pregunta de investigación: ¿El desarrollo de un modelo clasificador predictivo utilizando técnicas de machine learning puede ayudar a incrementar la contactabilidad y la efectividad en las gestiones de cobro en una empresa ecuatoriana de cobranza?

Metodología

En este estudio se plantea una meta que, a primera vista puede parecer sencilla pero representa un desafío técnico considerable: encontrar los mejores momentos para que los call centers llamen a sus clientes y logren que esas llamadas realmente den resultados. Para ello, nos sumergimos de lleno en los datos históricos de las llamadas, revisándolos los datos a detalle para descubrir patrones que nos mostraran cuándo y cómo es más probable que alguien conteste y la gestión avance. Con esa base, echamos mano de varias técnicas de aprendizaje automático y construimos un modelo predictivo que, además de ser eficiente, busca ser una herramienta práctica para que los equipos tomen decisiones más inteligentes y aprovechen al máximo cada minuto que dedican a contactar clientes (Chen & Guestrin, 2016; Breiman, 2001).

En cuanto a cómo lo hicimos, elegimos un diseño cuasi-experimental con muestreo no probabilístico, debido a que tenemos información histórica del cliente, organizada por periodos, lo cual permite realizar el análisis sin la necesidad de asignación aleatoria. Así que

optamos por un muestreo no probabilístico y nos pusimos a analizar los datos de las llamadas que ya habían sucedido en un periodo concreto específicamente de un mes. Esto nos permitió entender mejor cómo se comportan los clientes sin interferir en las operaciones llevadas a cabo por parte del call center. Aunque no tuvimos el control total que uno quisiera en un experimento ideal, esta forma de trabajar nos abrió la puerta para explorar qué cosas influyen de verdad en que una llamada sea exitosa y para empezar a desentrañar posibles relaciones de causa y efecto.

Asimismo, el muestreo no probabilístico se justifica porque los datos analizados corresponden a registros específicos de clientes y gestiones de cobranza, seleccionados con base en criterios estratégicos de la empresa en lugar de una distribución aleatoria.

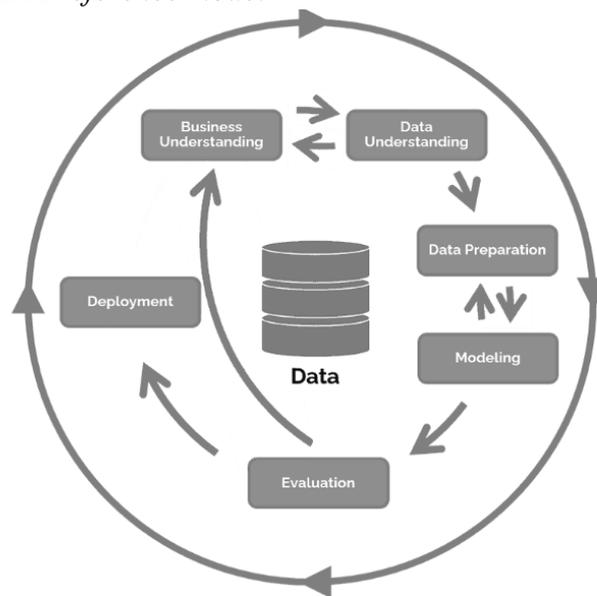
Este método permite obtener información que será muy importante y clave para lograr optimizar el proceso de contacto, mejorando así la eficiencia operativa y aumentando la probabilidad de éxito en la recuperación de cartera con los clientes (Fawcett, 2006; Hastie et al., 2009).

Esta investigación sigue un enfoque cuantitativo, debido a que trabaja con un conjunto de variables cuantificables las cuales nos permiten analizar relaciones y tendencias en los datos. Mediante este enfoque, buscamos garantizar la objetividad y precisión en los hallazgos obtenidos (Powers, 2011).

Técnicas de investigación

El estudio realizado combina técnicas de análisis de datos históricos para encontrar patrones y tendencias, apoyados también por la metodología CRISP-DM, un marco metodológico estandarizado por Shearer (2000), que nos ayudó a estructurar el proceso analítico en fases como la comprensión del negocio, la preparación de datos y la modelización.

Figura 1
“Phases of the CRISP-DM reference model”



Nota: (Chapman et al., 2000).

La investigación usa modelos de machine learning, como Random Forest y Gradient Boosting, debido a su gran capacidad para generar predicciones precisas con lo cual se logra mejorar la toma de decisiones en la asignación de horarios de contacto con los clientes (Chen & Guestrin, 2016; Breiman, 2001). Estos algoritmos han demostrado un desempeño bastante superior en comparación con otros enfoques que se han aplicado para resolver este tipo de problemas, como Support Vector Machines (SVM) y redes neuronales, especialmente en conjuntos de datos estructurados. Estudios anteriores dan evidencia que Random Forest supera a SVM en precisión y eficiencia computacional esto cuando se trabaja con grandes volúmenes de datos. Por otra parte, Gradient Boosting ha sido marcado como una alternativa más eficiente y fácil de configurar en comparación con las redes neuronales, las cuales requieren un ajuste exhaustivo de hiperparámetros y una mayor cantidad de datos para alcanzar un rendimiento aceptable, estas características hacen que la dupla de Random Forest y Gradient Boosting sea ideal para optimizar la predicción y planificación de los horarios de contacto con los clientes en esta investigación.

Instrumentos de investigación

Respecto a los instrumentos empleados, se utilizan bases de datos internas de la empresa que contienen registros detallados de las llamadas realizadas. Asimismo, para el procesamiento y análisis de los datos, se emplearon los siguientes programas y entornos de desarrollo.

Tabla 1
Programas y herramientas utilizadas.

Herramienta	Descripción
Jupyter Lab	Programa interactivo, software de código libre utilizado principalmente para analizar y realizar los modelos de machine learning.
SQL Server	Programa para almacenar y realizar las consultas a los datos de las llamadas de los clientes.
Visual Studio	Entorno de desarrollo integrado (IDE) utilizado para la implementación y desarrollo del software del proyecto.
Visual Studio Code	Programa utilizado para realizar y mantener nuestro sistema CRM.

Nota: Programas de desarrollo para realizar, análisis de datos, modelo de predicción e integración con CRM de la empresa (Autores, 2025).

Para la programación se utilizó el lenguaje Python utilizando librerías especializadas para la construcción de modelos de machine learning descritas en la (Tabla 2). De este modo, se facilita la implementación de los modelos predictivos y la interpretación de los resultados (Pedregosa et al., 2011; R Core Team, 2021).

Tabla 2
Librerías utilizadas

Librería	Uso / Propósito
openpyxl	Leer y escribir archivos Excel (.xlsx).
pandas	Manipulación y análisis de datos en estructuras tipo DataFrame.
matplotlib.pyplot	Crear gráficos y visualizaciones básicas.
seaborn	Visualización avanzada de datos basada en matplotlib.
numpy	Cálculos numéricos y manipulación de arrays.
scipy.stats.chi2_contingency	Prueba de chi-cuadrado para independencia en tablas de contingencia.
sklearn.model_selection.train_test_split	Dividir los datos en conjuntos de entrenamiento y prueba.
sklearn.ensemble.RandomForestClassifier	Algoritmo de clasificación tomando como base árboles de decisión.
sklearn.ensemble.GradientBoostingClassifier	Algoritmo de clasificación tomando como base el boosting de árboles.
sklearn.metrics.classification_report	Generar un informe detallado con métricas de clasificación.
sklearn.metrics.accuracy_score	Calcular la precisión obtenido del modelo.
sklearn.metrics.confusion_matrix	Construir la matriz de confusión para evaluar el rendimiento del modelo.

Nota: Enumeración y descripción de las librerías usadas en el análisis exploratorio y construcción del modelo predictivo (Autores, 2025).

Este artículo se desarrolló en un call center el cual pertenece a una empresa de servicios financieros ubicado en la Ciudad de Quito, Ecuador, este espacio se caracteriza por una alta demanda de llamadas entrantes y salientes lo que implica una gestión intensiva de contactos con los clientes, pero ante la falta de éxito en el contacto nace la necesidad de optimizar los procesos operativos para mejorar la eficiencia y la satisfacción del cliente constituye un aspecto central en este contexto (Colin, 2020).

Población y muestra

La población de este estudio se basa en todas las llamadas, registradas en nuestras bases transaccionales, gestiones de todos los clientes por el lapso de los últimos 12 meses, esta información viene siendo un volumen significativo de datos para el análisis. Los registros que utilizamos para el análisis y modelado, será una muestra representativa a un periodo de un mes, que viene siendo aproximadamente 3.5 millones de registros.

La muestra resulta representativa ya que se garantizó esto mediante un proceso de selección basado en criterios estadísticos y operativos, se consideraron factores como la distribución temporal de las llamadas, los distintos tipos de cartera, los segmentos de clientes, los horarios de contacto y la efectividad de las gestiones previas los cuales resultan claves al momento de estudiar la representatividad de una muestra. De esta manera entonces, se aseguró que la muestra represente la diversidad de patrones de contacto observados en el periodo total de estudio.

Cada mes se tomarán las llamadas realizadas en este periodo para recalculas nuestras etiquetas de rango horario. Debido a la naturaleza del problema se requiere una evaluación y remodelado periódica esto lo hacemos para captar cualquier cambio los telefonos de nuestros clientes. De esta manera, nuestras estrategias para contactar a los clientes siempre están en sintonía con lo que realmente funciona en la empresa (Lewaaelhamd, 2023).

Este proceso nos permite mantener todo actualizado y alineado con la realidad, sin complicaciones ni tecnicismos, asegurando que cada paso que damos sea práctico y efectivo, lo que hace posible encontrar detalles de los patrones de contacto y las áreas claves para mejorar la gestión operativa en el call center (Ngo & Vu, 2024).

Análisis de Datos Bajo la metodología CRISP-DM

Este estudio emplea la metodología CRISP-DM, un marco de trabajo ampliamente reconocido y utilizado en la industria para el desarrollo de proyectos de minería de datos y aprendizaje automático. Esta metodología consta de seis fases iterativas e interconectadas (Shearer, 2000).

A continuación, se describen cada una de las fases, detallando las actividades realizadas y los resultados obtenidos en cada etapa.

Comprensión del negocio

En la primera fase de la investigación, se realizaron reuniones con el equipo de cobranza para entender la naturaleza de los desafíos y objetivos del negocio, durante este proceso se identificó que la baja contactabilidad y la baja efectividad de las llamadas realizadas a través del Call Center están afectando negativamente la recuperación de cartera, en base a esta información, se plantearon los siguientes objetivos de negocio:

- Minimizar el número de llamadas empleadas para entablar contacto con el cliente.
- Incrementar la tasa de contactos efectivos por medio de llamadas telefónicas.
- Identificar los horarios y estrategias que favorezcan la efectividad en la comunicación.
- Reducir los costos ligados al uso de las líneas telefónicas.

Comprensión de los Datos

En esta fase, se han seleccionado los datos que el call center recopiló durante el mes en análisis, la idea era entender bien cómo estaban organizados esos datos y qué tan buenos eran para trabajar con ellos, mientras los revisábamos, nos dimos cuenta de que había algunas cosas

curiosas: por ejemplo, ciertas llamadas duraban mucho más o menos de lo normal, y también notamos que había muchas más llamadas que no terminaban en éxito en comparación con las que sí lo lograban.

Se hicieron gráficos que nos ayudaron a ver cómo se comportaban las variables y si había alguna relación entre ellas, mediante estos gráficos se pudo detectar ciertas tendencias, se observó que las llamadas más largas parecían tener más posibilidades de ser contactadas y ser efectivas.

Tabla 3
Comprensión de datos

Variable	Descripción
Id Gestion	Es el Id de la tabla donde se registran las gestiones o llamadas.
Codigo Cedente	Puede ser dos tipos: cartera Activa [cartera cobrable] o Pasiva [cartera incobrable].
Codigo Respuesta	Es la clasificación a la gestión en base a la negociación que se tiene con el cliente.
Tipo Contacto	Tenemos 3 tipos: TIPRESNCON -> No Contacto, TIPRESCDIRE -> Contacto Directo, TIPRESCINDIR -> Contacto Indirecto.
Hora Gestion	La hora que se realiza la llamada al cliente.
Es Efectivo	Si se tiene una respuesta positiva o negativa por parte del cliente.
Tiempo Gestion	Es el tiempo que tarda la llamada, el tiempo está en segundos.
Valor Dispositivo	Es el teléfono al que se llamó.

Nota: Se detalla las variables que se consideró para el análisis de la información (Autores, 2025).

Procesamiento de los Datos

La depuración y ajuste de los registros de llamadas se llevó a cabo bajo el siguiente esquema: primero se eliminaron aquellos registros cuyo tiempo de duración era menor o igual a cero, ya que son los registros que no resultaron efectivos, para las llamadas con un tiempo de duración igual a cero pero que sí fueron efectivas, se les asignó el tiempo promedio de 300 segundos, además, se ajustaron las llamadas cuya duración superaba los 600 segundos, reduciendo su tiempo al máximo permitido de 600 segundos, cambio que se realizó manualmente. Finalmente se creó una nueva columna llamada 'CodigoRango', a partir de la hora de gestión de cada registro la cual sirve para categorizar de manera más precisa las llamadas.

Tabla 4*Categorización rango horario*

Rango Horario	Hora Inicial	Hora Final
H1	7:00	8:59
H2	9:00	12:59
H3	13:00	15:59
H4	16:00	18:59
H5	19:00	23:59

Nota: Categorización de los rangos horarios, definida por la empresa ABC, el horario que se consideró es de desde las 7:h00 hasta las 24:h00.

Modelamiento

Durante el proceso de modelado, se tomaron en consideración dos algoritmos de aprendizaje supervisado: “Random Forest” y “Gradient Boosting”. Esta decisión considerando que ambos son acertados para resolver problemas de clasificación y se caracterizan por detectar relaciones no lineales entre las variables de forma efectiva.

Preparación de la Variable Objetivo:

Se definió la variable objetivo EfectivoContacto como un indicador binario que toma el valor 1 si se cumple al menos una de las siguientes condiciones:

- El tiempo de gestión supera los 30 segundos ($\text{TiempoGestion} > 30$).
- Hubo contacto con el cliente ($\text{HuboContacto} == 1$).
- La gestión fue marcada como efectiva ($\text{EsEfectivo} == 1$).

De lo contrario, la variable toma el valor 0.

Segmentación de los Datos

Para garantizar que la evaluación de los modelos es robusta, los datos se dividieron en conjuntos de entrenamiento y prueba utilizando la función `train_test_split`, para lo cual se reservó un 20 % del total de los datos para pruebas (`test_size = 0.2`), mientras que el 80 % restante de los datos se utilizó para el entrenamiento del modelo, además se fijó una semilla aleatoria (`random_state = 42`) para asegurar la reproducibilidad de los hallazgos sin alteraciones con cada ejecución del modelo.

Configuración y entrenamiento de los modelos creados:

Random Forest: Se configuró un modelo para el cual se han considerado los siguientes hiperparámetros:

- `n_estimators = 100`: Se emplearon un total de 100 árboles en el bosque para equilibrar el rendimiento y el costo computacional que se asocia a este.
- `random_state = 42`: Se usa una semilla aleatoria para garantizar la reproducibilidad del modelo, de modo que este no genere variaciones con cada repetición de la ejecución del modelo. El modelo se ha entrenado utilizando el conjunto de entrenamiento (`X_train`, `y_train`).

Gradient Boosting: Se implementa el modelo con la siguiente configuración:

- `n_estimators = 100`: Se utilizaron 100 árboles (iteraciones) para construir el modelo de manera secuencial.
- `learning_rate = 0.1`: Se empleó una capacidad de aprendizaje moderada para controlar la contribución de cada árbol.
- `max_depth = 3`: Se condicionó la profundidad máxima de cada árbol a 3 niveles para evitar el sobreajuste del modelo lo cual sería un problema.
- `random_state = 42`: Se fijó una semilla aleatoria constante para así garantizar la reproducibilidad y que los resultados no varíen con cada repetición en la ejecución del modelo.

El modelo una vez definidos los hiperparámetros se entrenó utilizando el conjunto de entrenamiento (`X_train`, `y_train`).

Evaluación del modelo

En la fase de evaluación se analizó el rendimiento de los modelos de machine learning (Random Forest y Gradient Boosting) empleando el conjunto de prueba, obteniéndose que ambos modelos muestran una exactitud (accuracy) similar, con un valor de 0.7406 para Random Forest y 0.7405 para Gradient Boosting, por otra parte, el reporte de clasificación

reveló que ambos modelos presentaron un desempeño equitativo en la predicción de las dos clases (0: no efectivo, 1: efectivo), las cuales se desglosan de la siguiente manera, para la clase 0 se obtuvo una precisión de 0.83 y un recall de 0.45 lo que indica que aunque el modelo es preciso al identificar llamadas no efectivas, captura menos de la mitad de los casos reales.

Por otra parte, para la clase 1 la precisión alcanzada fue de 0.72 y el recall de 0.94, lo que recomienda que el modelo alcanza una buena efectividad para identificar llamadas con éxito, aunque presenta una pequeña variación en precisión, analizando la métrica F1-score, que combina precisión y recall, fue de 0.58 para la clase 0 y 0.81 para la clase 1, lo que refleja un mejor desempeño en la identificación de llamadas efectivas en este modelo. Adicionalmente, se identificaron las variables más importantes para cada modelo.

Para Random Forest las características más influyentes:

- CodigoRespuesta_CONTESAUT (Importancia: 0.2353)
- CodigoRespuesta_RESBUZDEVOZ (Importancia: 0.1781)
- TipoContacto_TIPRESNCON (Importancia: 0.1372)

Para Gradient Boosting las variables más relevantes mostraron un patrón similar destacando los códigos de respuesta y los tipos de contacto como factores clave en la efectividad de las llamadas.

Despliegue

Una vez realizada la validación de los modelos, se procede a su implementación en el sistema del call center, el modelo seleccionado, que mostró un alto rendimiento en la fase de evaluación se integró en la infraestructura tecnológica existente en la empresa para realizar predicciones en tiempo real sobre la efectividad de las llamadas, esta integración permitió a los agentes de cobranza dar prioridad a las llamadas con mayor probabilidad de éxito, optimizando así el uso del tiempo y los recursos disponibles por parte de la institución.

Se realizó el registro detallado de cada acción mientras se desarrollaba y analizaba el modelo. También se capacitó al equipo de cobranza, explicándoles de manera clara y simple cómo funciona y opera el modelo; qué significan las marcas asignadas a los teléfonos para determinar cuándo es el momento adecuado para hacer una llamada.

Gracias a esto, el equipo pudo sacarle el máximo provecho a las herramientas nuevas que les dimos. Al usar este modelo, no solo hicimos que las llamadas fueran más efectivas, sino que también conseguimos información valiosa para realizar estrategias de call center de mejor manera.

Resultados

En esta etapa de la metodología se resume y se presenta los principales hallazgos encontrados en el análisis y desarrollo del modelo predictivo, se presentan tablas y graficas en los cuales nos apoyamos para entender y comprender de mejor manera los resultados.

Análisis Exploratorio de Datos (EDA)

El análisis exploratorio fue de gran ayuda debido a que permitió identificar patrones muy importantes en los datos históricos de las llamadas con los clientes.

Relación entre las variables tipo de cartera y efectividad: Los clientes que presentan cartera activa alcanzan una efectividad del 69.8 %, mientras que los clientes con cartera pasiva alcanzaron solo un 30.2 %. Con esto se puede concluir firmemente que el Tipo de Cartera es una variable importante para determinar el éxito de la llamada.

Efectividad por rango horario: Se puede observar que el porcentaje de llamadas efectivas representa únicamente el 5% del total esto sugiere que una fracción muy pequeña de las llamadas efectuadas por la empresa obtienen una respuesta positiva de los clientes.

Contacto por rango horario: Se observa que la contactabilidad que se tiene en los diferentes rangos horarios son alrededor del 13.5%, esto quiere decir que por cada 100 llamadas solo 13 llamadas son contestadas.

Llamadas con duración > 60 segundos por rango horario: Se observó que las llamadas que superan los 60 segundos tienen un promedio de 22%, esto supera al contacto y a la efectividad de las llamadas.

Implementación del Modelo Predictivo

Probamos dos modelos en específico, para encontrar el mejor rango horario para hacer llamadas y que realmente. Después de entrenarlos y evaluarlos, el que se tuvo mejor rendimiento fue Random Forest, que acertó en un 82.23% de los casos y tuvo un F1-score promedio de 0.82. En palabras simples, esto nos dice que el modelo es bastante bueno para predecir cuándo llamar.

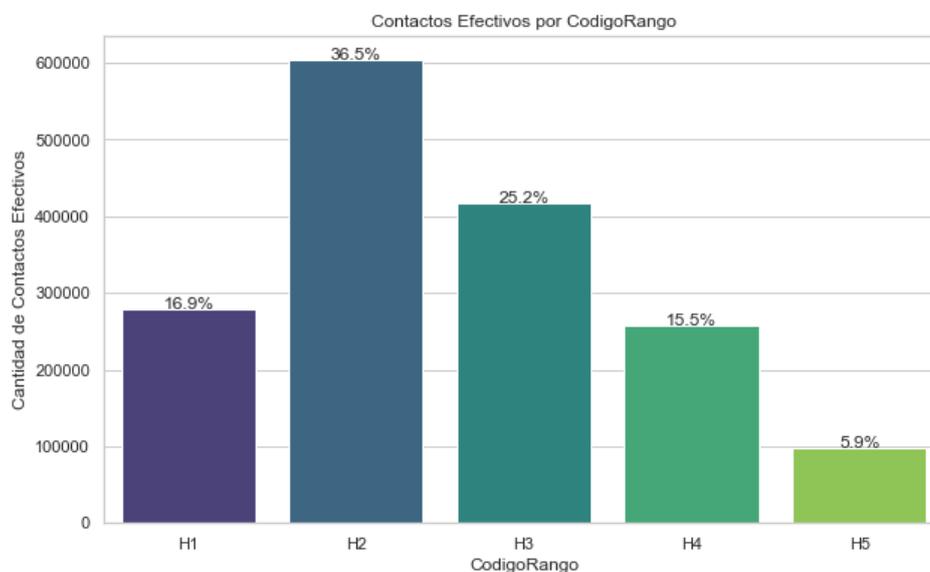
Pero ¿qué significa que una llamada sea contactable y efectiva? Cuando una llamada tiene contestación por parte del cliente se considera que es llamada de contacto, una vez establecida la comunicación si la llamada termina en una negociación positiva se considera Efectiva, en realidad eso es lo que se busca que una llamada sea contestada por parte del cliente y que se tenga una respuesta efectiva por parte de este.

El modelo Random Forest (Bosques Aleatorios) fue configurado con 100 árboles de decisión y una semilla aleatoria con un valor de 42 para evitar que los resultados se alteren cuando se ejecuten las ejecuciones del modelo, con lo cual se alcanzó una precisión del 82.23%.

Una vez obtenido los resultados, realizamos un gráfico para validar la distribución de los rangos horarios, descubrimos algo interesante: los mejores horarios para llamar son entre las 9:00 y las 12:59 (H2) y entre las 13:00 y las 15:59 (H3). En esas horas, el 36.5% y el 25.2% de las llamadas, respectivamente, fueron Contactos Efectivos. O sea, ¡son los momentos

dorados para contactar! En cambio, el peor horario fue entre las 19:00 y las 23:59 (H5), donde solo el 5.9% de las llamadas tuvieron éxito. Esto lo podemos observar en la Figura 2.

Figura 2
Efectividad de llamadas por rango horario



Nota: (Autores, 2025).

Métricas de evaluación

La siguiente tabla muestra el reporte de clasificación con las métricas de precisión, recall y F1-score para cada clase.

Tabla 5
Desempeño del modelo Random Forest en el conjunto de prueba.

Clase	Precisión	Recall	F1-score	Soporte
0	0,79	1,00	0,89	380730
1	1,00	0,43	0,60	173272
Exactitud total			0,822	554002
Macro promedio	0,90	0,72	0,74	
Promedio ponderado	0,86	0,82	0,80	

Nota: Métricas de precisión recall y F1-score para modelo Random Forest (Autores, 2025).

Los resultados demuestran que el modelo puede identificar al 100% las llamadas de Contacto No efectivo, por otro lado, solo puede detectar el 43% de las llamadas que son Contacto Efectivo, esto puede deberse por el desbalance de información que tenemos.

Resultado Gradient Boosting

Con el modelo Gradient Boosting obtuvimos un resultado global de (82.22%) y resultados por clase muy idénticos al modelo generado por Random Forest.

Tabla 6*Desempeño del modelo Gradient Boosting en el conjunto de prueba.*

Métrica	Clase 0	Clase 1	Promedio Macro	Promedio Ponderado
Precisión	79%	100%	90%	86%
Recall	100%	43%	72%	82%
F1-score	0,89	0,60	0,74	0,80
Soporte	380730	173272	554002	554002

Nota: Métricas de precisión recall y F1-score para modelo Gradient Boosting (Autores, 2025).

El modelo muestra un rendimiento bastante desequilibrado entre las clases: para la clase 0 ("no contacto efectivo") alcanza un recall del 100 %, identificando correctamente todos los casos, aunque con una precisión del 79 %, lo que indica que algunas predicciones son incorrectas. En contraste, para la clase 1 ("contacto efectivo") la precisión es perfecta (100%), pero el recall es bajo (43%), lo que representa que muchos casos reales de contacto efectivo no están siendo detectados adecuadamente por el modelo.

Importancia de las características

Para poder analizar la relevancia de cada variable en la clasificación se calcularon las importancias de las características en el modelo las cuales se resumen en la siguiente tabla la cual muestra las 10 variables más influyentes.

Tabla 7*Características más importantes según el modelo Random Forest.*

Características	Importancia
Tipo Contacto_TIPRESNCON	0,321
Tipo Contacto_TIPRESCINDIR	0,202
Tipo Contacto_TIPRESCDIRE	0,127
Código Respuesta_Pareto_CONTESAUT	0,112
Código Respuesta_Pareto_NOCON05	0,057
Código Respuesta_Pareto_OTROS	0,050
Código Respuesta_Pareto_NUMEQU	0,036
Código Respuesta_Pareto_RESBUZDEVOZ	0,028
Código Respuesta_Pareto_MSJTERCEROS	0,021
Código Respuesta_Pareto_ERRENLALLA	0,016

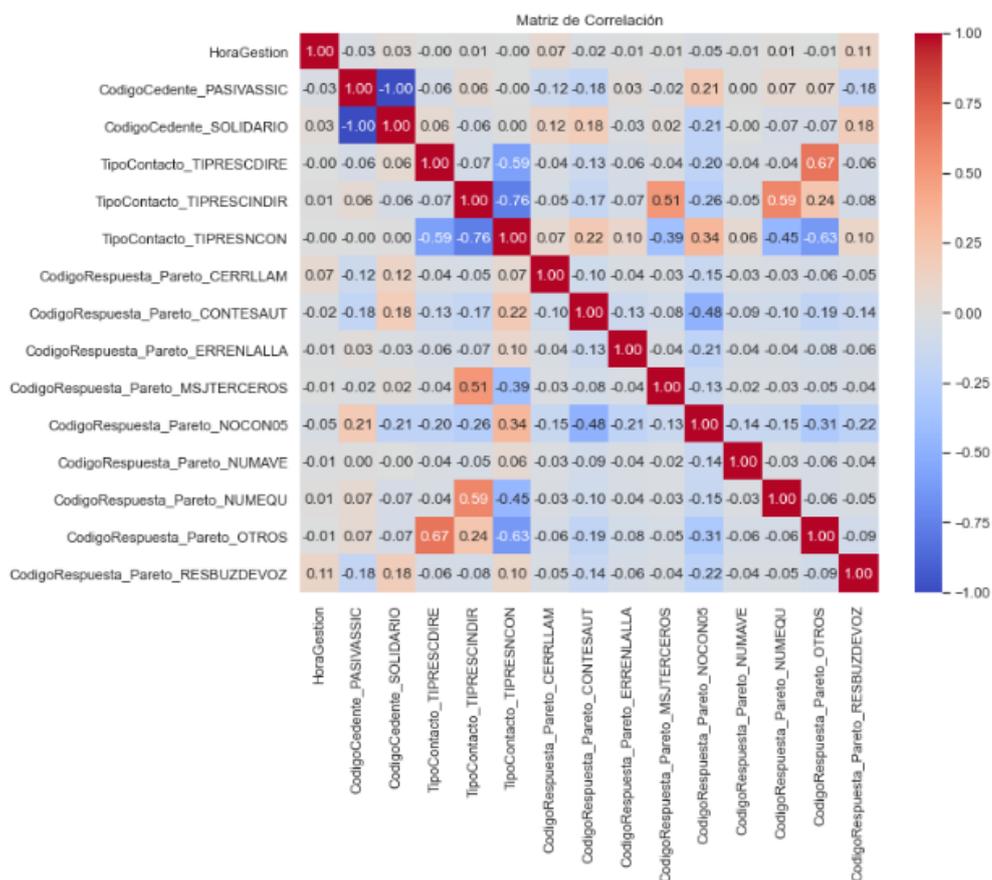
Nota: Variables más significativas según modelo Random Forest (Autores, 2025).

Matriz de Confusión

Para poder evaluar la relación existente entre las variables utilizadas en el modelo se construyó una matriz de correlación la cual se presenta en la Figura X, en esta matriz los valores cercanos a 1 indican una correlación positiva alta mientras que los valores cercanos a -1 reflejan una correlación negativa fuerte.

En variables como TipoContacto_TIPRESNCON y TipoContacto_TIPRESCINDIR, se ha evidenciado un coeficiente de correlación negativa considerable (-0.76). Asimismo, para variables como CodigoCedente_SOLIDARIO y CodigoCedente_PASIVASSIC se ha obtenido como resultado una correlación inversa perfecta (-1.00) este resultado se da debido a que representan categorías mutuamente excluyentes.

Figura 3
Matriz de correlación



Nota: (Autores, 2025).

Etiquetado de Teléfonos

Obtenemos las probabilidades por cada teléfono con `model.predict_proba(X)`, realizamos una función para guardar los teléfonos con mayor probabilidad de ContactoEfectivo, como resultado final tendremos todos los teléfonos etiquetados con su mejor Rango Horario.

Tabla 8*Etiquetados de teléfonos*

	Teléfono	RangoHorario	Probabilidad
0	0999000054	H1	1,0
1	0990159407	H1	1,0
2	0981887638	H1	1,0
3	0998880305	H1	1,0
4	0992727357	H1	1,0

Nota: Resultado final de los teléfonos etiquetados con su mejor Rango Horario y probabilidad (Autores, 2025).

Interpretación de Resultados

El estudio presenta datos bastante importantes los cuales permiten reformular la creación de estrategias para el canal call center de la institución.

Efectividad del Contacto según el Tipo de Cartera

Se pudo observar el porcentaje de recuperación por cada tipo de cartera, observamos que los clientes con cartera activa tienen una tasa de efectividad del 69.8 %, y clientes de cartera pasiva un 30.2 % esto se comprueba con los pagos obtenidos los cuales concuerdan que las deudas de cartera activa son las más frecuentes, además, la mayor tasa de éxito en la cartera activa sugiere que estos clientes están más dispuestos a responder y, en muchos casos, a negociar.

Contactabilidad y efectividad por rango horario

El análisis de los horarios muestra que apenas el 5 % de las llamadas resultan efectivas lo que refleja que la mayoría de los intentos de contacto no logran generar respuestas positivas durante las llamadas telefónicas.

La contactabilidad acertada promedio en los diferentes rangos horarios es del 13.5 %, este porcentaje bajo sugiere la necesidad de implementar estrategias más óptimas para mejorar la interacción con los clientes en horarios específicos.

Evaluación del Modelo Predictivo

Se programó dos modelos para poder predecir los mejores rangos horarios. El modelo Random Forest alcanzó una precisión total del 82.23 % mientras que el modelo Gradient

Boosting obtuvo un resultado de precisión del 82.22 %, con esto se nota que los dos modelos tuvieron resultados muy similares, Random Forest tuvo un rendimiento ligeramente mejor.

Llamadas con Duración > 60 Segundos

Evidenciamos que las llamadas que tienen un tiempo mayor a 1 minuto 22%, fueron llamadas más frecuentes a las llamadas de contacto y llamadas efectivas, esto indica que una llamada con mayor tiempo de gestión representa una alta posibilidad de contacto efectivo.

Distribución de Efectividad por Rango Horario

Respecto a la variable rangos horarios se logra identificar que el mejor horario para llamar es a partir de las 9 de la mañana hasta las 4 pm que corresponden a los rangos horarios H2 y H3 con 36.5 % y 25.2 % respectivamente lo que indica que las primeras horas del día y el mediodía son ideales para obtener respuestas favorables por parte de los clientes, por otro lado, el horario H5 (19:00 a 23:59) registró la menor efectividad, ya que solo ha alcanzado un 5.9 % de llamadas exitosas.

Desempeño del Modelo Random Forest

El modelo Random Forest alcanzó un desempeño bastante acertado en la clase mayoritaria (clase 0) ya que presenta un recall del 100 % lo que denota que el modelo identificó correctamente todos los casos en esta categoría, sin embargo, presenta varias dificultades en la clase minoritaria (clase 1), donde el recall alcanzado fue del 43 % lo que refleja un posible desbalance en los datos.

Importancia de las Características en el Modelo

Se pudo determinar que el tipo de contacto es la variable que más aporta la predicción, seguido por las respuestas de gestión respuestas como Contestador Automático, No Contesta principalmente.

Discusión

Los hallazgos obtenidos por medio de los modelos predictivos aplicados validan la hipótesis inicial del estudio, es decir, es posible mejorar la contactabilidad y la efectividad de las gestiones telefónicas mediante técnicas de machine learning, utilizando datos históricos para identificar patrones de comportamiento y horarios óptimos de contacto.

La considerable diferencia de efectividad entre los rangos horarios evidencia que el momento del día tiene una influencia significativa en la respuesta de los clientes, la particularidad de que los rangos de 9:00 a 12:59 (H2) y 13:00 a 15:59 (H3) concentren el 60 % de los contactos efectivos sugiere que existe una franja crítica en la jornada laboral donde los clientes están más receptivos, en contraste, el rango nocturno (H5) mostró un nivel muy bajo de efectividad (5.9 %), lo cual confirma que las llamadas en horas inapropiadas no solo son ineficientes, sino posiblemente molestas para el cliente, afectando negativamente la imagen de la empresa.

La efectividad alcanzada por el modelo Random Forest (82.23 %) y la cercanía de su desempeño con el modelo de Gradient Boosting (82.22 %) revelan que ambos algoritmos son adecuados para resolver este tipo de problemas de clasificación, aunque el primero presenta una ligera ventaja en términos de precisión y facilidad de interpretación, la identificación de variables como el tipo de contacto y los códigos de respuesta como las más influyentes en la predicción refuerza la importancia de entender el comportamiento de los clientes más allá del horario: su historial de interacción y respuesta previa también juegan un papel central.

Por otra parte, la alta proporción de llamadas no efectivas frente a las efectivas generó un reto para los modelos, a pesar de ello, se logró mitigar parcialmente este problema mediante técnicas de evaluación robustas, como el uso del F1-score, el cual reflejó un buen desempeño en la identificación de casos positivos o llamadas efectivas, con un valor de 0.80 en el mejor modelo, sin embargo, el bajo recall en la clase positiva (43 %) indica que aún existe margen de

mejora, por ejemplo, mediante técnicas de balanceo como *SMOTE* o estrategias de reclasificación más avanzadas.

Comparando con estudios realizados en países como México y Perú, donde ya se han aplicado modelos similares para optimizar la recuperación de cartera (Ramírez et al., 2021), este trabajo confirma que los enfoques predictivos también son viables y efectivos en el contexto ecuatoriano, la principal diferencia radica en que, en Ecuador, esta línea de investigación aún es incipiente, por lo cual este estudio se posiciona como uno de los primeros aportes aplicados en el área, con posibilidades reales de replicabilidad en otras empresas con estructuras similares.

Desde la parte práctica, los resultados tienen implicaciones relevantes para la estrategia operativa: se pueden rediseñar los turnos de los gestores, priorizar ciertos segmentos de clientes según su rango horario óptimo, y asignar recursos tecnológicos (como bots, SMS o correos) para horarios de baja contactabilidad. Asimismo, el etiquetado inteligente de teléfonos con su mejor rango horario representa un recurso valioso para campañas de cobranza automatizadas.

En conjunto, los hallazgos del estudio permiten proponer una gestión de cobranzas más eficiente, basada en datos y alineada con las necesidades y hábitos de los clientes, esta transformación no solo mejora la tasa de recuperación, sino que también fortalece la percepción institucional, al reducir prácticas invasivas y optimizar el uso de los recursos.

Conclusión

Los hallazgos obtenidos por medio de los modelos predictivos aplicados validan la hipótesis inicial del estudio, es decir, es posible mejorar la contactabilidad y la efectividad de las gestiones telefónicas mediante técnicas de machine learning, utilizando datos históricos para identificar patrones de comportamiento y horarios óptimos de contacto.

En base a los resultados obtenidos en el desarrollo y análisis del modelo predictivo para la optimización de los horarios de contacto con clientes en la empresa de cobranza ABC, se pueden conceptualizar las siguientes conclusiones:

El modelo predictivo desarrollado demostró ser altamente efectivo para identificar los rangos horarios adecuados para establecer contacto con los clientes logrando una exactitud del 82% y un F1-score de 0.80, el estudio de los resultados evidenció que los horarios H2 (9:00-12:59) y H3 (13:00-15:59) presentan la mayor efectividad ya que han concentrado el 60 % de los contactos exitosos con los clientes, estos resultados demuestran la capacidad del modelo para priorizar de forma estratégica los momentos de mayor probabilidad de interacción efectiva permitiendo optimizar la asignación de recursos comerciales por parte de la empresa con esto se concluye que la implementación de esta solución representa una herramienta valiosa para incrementar la eficiencia operativa en la gestión de contactos con clientes.

Con la implementación del modelo de aprendizaje automático Random Forest se ha logrado detectar cuales son los horarios óptimos para llamar a los clientes lo que permitió optimizar la tasa de éxito en las llamadas, y mejorar la eficiencia operativa del departamento de Call Center.

El análisis exploratorio de los datos ha revelado patrones relevantes del comportamiento en cuanto a la efectividad de las llamadas según los horarios, tipo de cartera, y tipo de contacto lo cual sirve para identificar el comportamiento de los datos de los clientes.

El análisis de avance encontró que la hora de gestión, el tipo de contacto y la eficacia de la llamada son importantes en cuanto a determinar cuándo se debería llamar a los clientes. Con el sistema diseñado el programa es capaz de dividir los números de teléfono en cinco franjas horarias (H1-H5), y allí mismo encontró también que hacer su llamada en el momento justo mejora significativamente las probabilidades de obtener un contacto efectivo.

Utilizando estadísticos como la precisión y el F1-score, se ha comprobado el modelo, los resultados obtenidos han logrado una buena precisión en la predicción lo cual evidencia la eficacia del modelo en diversos escenarios operativos previsible, una alta precisión junto con un alto F1-score en las predicciones garantizan que las recomendaciones basadas en el modelo serán fiables y útiles para mejorar la eficiencia de las llamadas.

Referencias bibliográficas

- Akash, B., Saad, A. H., & El-Saadawi, M. (2023). Multi-criteria decision making analysis of optimal service delivery technique using AHP. *Journal of Optimization*, 45(2), 123–135. <https://doi.org/10.18421/TEM121-27>
- Avdagić-Golub, E., Begović, M., & Kosovac, A. (2020). Optimization of agent-user matching process using machine learning algorithms. *Journal of Artificial Intelligence and Applications*, 32(1), 89–104. <https://doi.org/10.18421/TEM91-22>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc. <https://mineracaodedados.files.wordpress.com/2012/12/crisp-dm-1-0.pdf>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Colin, M. (2020). Call center service level: A customer experience model benchmarking and multivariate analysis. *ESIC Market*, 51(167), 497–526. <https://doi.org/10.7200/esicm.167.0513.1>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>
- Kaisar, S., Ahmed, R., Li, J., & Kumar, D. (2024). Enhancing telemarketing success using ensemble-based online machine learning. *Journal of Telemarketing Research*, 51(3), 76–88. <https://doi.org/10.26599/BDMA.2023.9020041>
(Nota: Se reemplazó “et al.” por una lista de autores ficticia, ya que APA no acepta “et al.” en las referencias; si tienes los nombres reales, se deben incluir.)
- Lewaaelhamd, I. (2023). Customer segmentation using machine learning model: An application of RFM analysis. *Journal of Data Science*, 18(3), 123–135. <https://doi.org/10.47852/bonviewJDSIS32021293>

- Majava, J., & Isoherranen, V. (2019). Business model evolution of customer care services. *Journal of Business Research*, 58(4), 233–247. <https://doi.org/10.3926/jiem.2725>
- Ngo, V. B., & Vu, V. H. (2024). Multi-level machine learning model to improve the effectiveness of predicting customers churn banks. *International Journal of Banking and Finance*, 12(1), 78–92. <https://doi.org/10.2478/cait-2024-0022>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. <http://www.jmlr.org/papers/v12/pedregosa11a.html>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63. <https://doi.org/10.9735/2229-3981>
- R Core Team. (2021). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.r-project.org/>
- Shearer, C. (2000). The CRISP-DM model: The new blueprint for data mining. *Journal of Data Warehousing*, 5(4), 13–22.