

**Análisis de las estrategias de retención y predicción de abandono de clientes (Churn) en el sector de las telecomunicaciones mediante el aprendizaje automático**

Andres Felipe Ramirez Niño

Director

Jorge Eliecer Ospino Portillo

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería - ECBTI

Especialización en Ciencia de Datos y Analítica

2026

## Resumen

El presente trabajo de monografía se centra en el análisis comparativo y la justificación estratégica de las metodologías de Aprendizaje Automático (ML) aplicadas a la Predicción de Abandono de Clientes (*Churn Prediction*) en el sector de las telecomunicaciones.

La investigación se justifica en la necesidad de migrar de una gestión de clientes reactiva a una proactiva, dado que el Abandono (*Churn*) es el principal riesgo financiero del sector. La capacidad de anticipación, impulsada por el ML, genera "grandes ahorros" al permitir la focalización de las acciones de retención (Alegre, 2020).

La metodología empleada es un análisis documental cualitativo basado en la revisión de tres trabajos de especialización clave, complementados con literatura científica. Este análisis se enfoca en identificar, describir y comparar los enfoques metodológicos.

Los resultados demuestran el predominio de modelos no lineales y de ensamble sobre enfoques estrictamente lineales. En los referentes primarios, las Redes Neuronales Artificiales (RNA) alcanzan desempeños altos (Pinto & Gutiérrez, 2023), mientras que los modelos basados en árboles y técnicas de boosting (Random Forest, XGBoost, LightGBM) muestran robustez y buen equilibrio entre rendimiento y estabilidad (Alegre, 2020; Falla Arango, 2021; Santamaría Guzmán, 2024). Sin embargo, estudios comparativos evidencian que la selección del "mejor" modelo depende de la métrica crítica del negocio (p. ej., sensibilidad/recall vs accuracy) y del costo de errores (Castro Rodríguez & Pérez Vázquez, 2020). En cuanto a variables, se confirma que los factores contractuales y de uso/consumo son los más influyentes, destacando Tenure y Tipo de Contrato, junto con cargos mensuales/totales y servicios asociados a Internet (p. ej., seguridad en línea) como predictores clave (Alegre, 2020; Zepeda Castillo et al., 2024).

La conclusión estratégica clave es que la predicción solo es efectiva si se integra con la Segmentación de Clientes (*Clustering*). La acción de retención es costo-efectiva únicamente cuando se dirige a clientes clasificados con ALTA PROBABILIDAD DE ABANDONO que pertenecen, simultáneamente, a segmentos de ALTO VALOR o rentabilidad para la compañía (Alegre, 2020). La monografía provee, por lo tanto, un marco analítico sólido para justificar la selección de algoritmos, la priorización de variables y la aplicación de la segmentación como pilar en la estrategia proactiva de retención de clientes Telco.

**Palabras clave:** Predicción de Abandono (*Churn Prediction*), Aprendizaje Automático (*Machine Learning*), Telecomunicaciones (Telcos), Algoritmos de Clasificación, Segmentación de Clientes (*Clustering*), Variables Predictivas, Retención de Clientes

## Abstract

This monograph focuses on the comparative analysis and strategic justification of Machine Learning (ML) methodologies applied to Customer Churn Prediction in the telecommunications sector.

The research is justified by the need to migrate from reactive to proactive customer management, given that churn is the sector's main financial risk. The anticipatory capabilities offered by ML generate significant savings by allowing for targeted retention efforts (Alegre, 2020).

The methodology employed is a qualitative documentary analysis based on a review of three key specialized works, supplemented by scientific literature. This analysis focuses on identifying, describing, and comparing methodological approaches.

The results demonstrate the superiority of complex models over linear ones. Artificial Neural Network (ANN) algorithms and Ensemble models such as Random Forest are the most effective, achieving the highest accuracy in the classification task (Pinto & Gutiérrez, 2023; Falla Arango, 2021). It is concluded that contractual and usage variables are the most influential, with Customer Tenure and Contract Type standing out as the factors with the greatest predictive power.

The key strategic conclusion is that prediction is only effective when integrated with Customer Segmentation (Clustering). Retention efforts are cost-effective only when they target customers classified as having a HIGH PROBABILITY OF CHURN who simultaneously belong to HIGH-VALUE or high-profit segments for the company (Alegre, 2020). This monograph therefore provides a solid analytical framework to justify the selection of algorithms, the

prioritization of variables, and the application of segmentation as a cornerstone of a proactive Telco customer retention strategy.

**Keywords:** Churn Prediction, Machine Learning, Telecommunications (Telcos), Classification Algorithms, Customer Segmentation (Clustering), Predictive Variables, Customer Retention

## Tabla de Contenido

Introducción .....	11
Planteamiento del Problema .....	12
Justificación .....	14
Objetivos .....	15
Objetivo General .....	15
Objetivos Específicos .....	15
Marco Conceptual .....	16
Marco Teórico .....	18
Metodología .....	20
Tipo de Investigación .....	20
Fuentes de Información .....	20
Estrategia de Búsqueda .....	21
Criterios de Inclusión .....	22
Criterios de Exclusión .....	22
Proceso de Selección y Registro .....	23
Criterios de Extracción y Síntesis de Datos .....	24
Criterio de Análisis .....	27
Resultados .....	28
Eficacia y Rendimiento de los Algoritmos de Clasificación .....	28
Identificación y Justificación de Variables Predictivas Clave .....	30
El Resultado Estratégico: Integración de Predicción y Segmentación .....	31
Síntesis de Evidencia Complementaria (2020–2025) .....	32

Conclusiones .....	38
Referencias Bibliográficas .....	40
Apéndices.....	42

**Lista de Tablas**

**Tabla 1** *Resultados del Análisis Comparativo de Referentes* ..... 33

**Tabla 2** *Fuentes de Análisis de la Monografía* ..... 35

## Lista de Figuras

**Figura 1** *Diagrama de Flujo PRISMA 2020 (Plantilla para Registrar el Proceso de Selección)*24

**Lista de Apéndices**

<b>Apéndice A</b> <i>Especificaciones Técnicas de Algoritmos Analizados</i> .....	42
<b>Apéndice B</b> <i>Métricas Detalladas de Rendimiento de Clasificación</i> .....	44
<b>Apéndice C</b> <i>Análisis de Importancia de Variables y Segmentación</i> .....	47

## Introducción

El sector de las telecomunicaciones (Telcos) se desenvuelve en un entorno de mercado altamente competitivo, donde la retención de clientes es crítica. Ante la evidencia de que conservar un cliente es más rentable que adquirir uno nuevo, la pérdida de usuarios o Abandono (*Churn*) se ha convertido en el principal desafío estratégico y financiero. Por ello, las empresas deben migrar hacia una gestión proactiva.

Para anticipar el *Churn*, la Predicción de Abandono se apoya en el Aprendizaje Automático (Machine Learning). Algoritmos como las Redes Neuronales, el Random Forest y la Regresión Logística permiten identificar patrones de riesgo tempranos utilizando datos de uso y variables contractuales (Falla Arango, 2021; Pinto & Gutiérrez, 2023). Este enfoque predictivo es fundamental, ya que "Poder predecir con cierta confianza si un cliente abandonará la compañía antes que suceda puede generar grandes ahorros" (Alegre, 2020).

El presente trabajo de monografía tiene como objetivo principal realizar un análisis exhaustivo y una discusión teórica de las metodologías y factores de riesgo utilizados en los referentes académicos sobre *Churn Prediction*. Nos enfocaremos en analizar los algoritmos de ML, justificar la relevancia de las variables predictivas clave, y evaluar el uso de la Segmentación de Clientes (*Clustering*) para priorizar las acciones de retención. Es importante aclarar que esta monografía se limita al análisis de resultados y procedimientos existentes, sin desarrollar ni implementar modelos predictivos propios.

## Planteamiento del Problema

El abandono de clientes (churn) en telecomunicaciones corresponde a la pérdida de usuarios que cancelan o migran su servicio, fenómeno que impacta directamente los ingresos recurrentes y obliga a las compañías a invertir de forma constante en adquisición y campañas de retención. En un mercado altamente competitivo, pequeñas variaciones en la tasa de churn pueden traducirse en pérdidas significativas y en presiones estratégicas sobre la sostenibilidad del negocio (Castro Rodríguez & Pérez Vázquez, 2020).

La literatura reciente plantea que la predicción temprana del churn, basada en aprendizaje automático, permite pasar de una gestión reactiva a una gestión proactiva, asignando recursos de retención de manera costo-efectiva hacia clientes con mayor probabilidad de abandono y, en particular, hacia segmentos de alto valor (Alegre, 2020; Pinto & Gutiérrez, 2023). Sin embargo, los estudios varían en los algoritmos evaluados (p. ej., Regresión Logística, Random Forest, redes neuronales y modelos basados en deep learning), en la selección de variables predictivas (contractuales, consumo, facturación, soporte y demográficas) y en las métricas reportadas, lo que dificulta comparar enfoques y extraer recomendaciones operativas consistentes.

En este contexto, el problema de investigación se centra en identificar, a partir de evidencia académica y aplicada (2020 en adelante), qué metodologías de aprendizaje automático y qué factores de riesgo (variables) son más utilizados y reportan mejor rendimiento para predecir el churn en el sector Telco, y cómo la segmentación de clientes (clustering) puede complementar la predicción para priorizar acciones de retención. La monografía aborda este problema mediante una revisión y análisis comparativo de referentes, organizada con un proceso de búsqueda y selección documentado.

*Pregunta guía: ¿Qué algoritmos y variables predictivas se reportan con mayor efectividad para la predicción de abandono de clientes en telecomunicaciones y de qué manera la segmentación contribuye a la priorización estratégica de la retención?*

## Justificación

La presente monografía se justifica plenamente dada la relevancia económica y estratégica de la Predicción de Abandono de Clientes (*Churn Prediction*) en el sector de las telecomunicaciones.

En un mercado tan competitivo, la retención de clientes es considerablemente más rentable que la adquisición de nuevos, haciendo del *Churn* el principal factor de riesgo para la sostenibilidad financiera. Este estudio se justifica al abordar cómo el Aprendizaje Automático (Machine Learning) es la herramienta esencial para implementar una gestión proactiva y preventiva, ya que la capacidad de anticipación puede "generar grandes ahorros" (Alegre, 2020) al identificar patrones de riesgo tempranos.

El valor central de esta monografía radica en su rigor analítico. Se revisan y comparan las metodologías (algoritmos como Redes Neuronales y Random Forest) y las variables clave utilizadas en los trabajos de especialización provistos (Falla Arango, 2021; Pinto & Gutiérrez, 2023). Al analizar y evaluar estos hallazgos, el estudio justifica las mejores prácticas para la toma de decisiones, la selección de variables y la priorización de las acciones de retención. De esta forma, el documento provee un marco teórico sólido y aplicable construido a partir de la síntesis y la crítica de conocimiento especializado.

## Objetivos

### Objetivo General

Analizar las metodologías de Aprendizaje Automático (Machine Learning) y los factores de riesgo clave (variables) utilizados en los trabajos de investigación para la Predicción de Abandono de Clientes (*Churn Prediction*) dentro del sector de las telecomunicaciones, con el fin de justificar la base estratégica para la toma de decisiones y la retención eficiente de usuarios.

### Objetivos Específicos

Identificar Algoritmos y Variables: Identificar los principales algoritmos de Aprendizaje Automático (como Redes Neuronales, Random Forest y Regresión Logística) y las variables predictivas clave (demográficas, de uso de servicio y contractuales) que son comunes en la documentación especializada sobre *Churn Prediction*.

Describir el Rendimiento: Describir detalladamente las métricas de rendimiento y precisión reportadas por los diferentes modelos de predicción de *Churn* analizados en los referentes, así como la metodología de aplicación de las técnicas de Segmentación de Clientes (*Clustering*).

Comparar la Efectividad: Comparar la efectividad de los algoritmos identificados según sus resultados y evaluar el impacto de la Segmentación de Clientes en la optimización de los recursos y la priorización costo-efectiva de las acciones de retención.

## Marco Conceptual

El fenómeno del Abandono de Clientes (*Churn*) se refiere a la terminación de la relación comercial de un usuario con su proveedor de servicios. En el ámbito de las Telecomunicaciones (Telcos), este abandono es una métrica financiera crítica, pues implica una pérdida de ingresos y de valor presente neto. Si bien existe el *Churn* involuntario (por impago), el enfoque principal es el voluntario, es decir, cuando el cliente decide migrar a la competencia, siendo este el factor directamente mitigable a través de estrategias proactivas (Alegre, 2020).

La Predicción de Abandono (*Churn Prediction*) es la disciplina que busca anticipar este comportamiento, utilizando modelos que estiman la probabilidad de que un cliente abandone en un horizonte temporal definido. Su objetivo es transitar de una gestión reactiva a una proactiva, permitiendo a la empresa concentrar sus esfuerzos de retención solo en aquellos usuarios identificados con alto riesgo. Esta predicción se logra mediante el Aprendizaje Automático (*Machine Learning - ML*), una rama de la Inteligencia Artificial que construye modelos capaces de identificar patrones complejos a partir de grandes conjuntos de datos históricos.

El ML se materializa a través de Algoritmos de Clasificación, que son los modelos matemáticos que asignan una probabilidad binaria (Abandona o No Abandona) a cada cliente. Los documentos de referencia analizados se centran en modelos robustos como la Regresión Logística, los Árboles de Decisión, los modelos de Ensamble como Random Forest, y las potentes Redes Neuronales Artificiales (RNA), que son eficaces para capturar relaciones no lineales en los datos (Pinto & Gutiérrez, 2023).

Para que estos algoritmos funcionen, requieren Variables Predictivas (*Features*), que son las características de los clientes utilizadas como *inputs* para el entrenamiento del modelo. Estas variables suelen categorizarse en: contractuales (tipo y duración del contrato, facturación), de uso

y servicio (consumo de datos, minutos, servicios adicionales) y demográficas (edad, género, etc.). La calidad y la selección de estas variables son determinantes en el rendimiento predictivo final.

Finalmente, la Segmentación de Clientes (*Clustering*) emerge como un proceso estratégico post-predicción. Si bien la predicción identifica el riesgo, el *Clustering* agrupa a los clientes según la similitud de sus características, permitiendo a la empresa priorizar las acciones de retención. De esta forma, los recursos se invierten solo en aquellos clientes en riesgo que pertenecen a segmentos rentables o estratégicos, optimizando la inversión y asegurando que la acción proactiva sea costo-efectiva (Alegre, 2020).

## Marco Teórico

El análisis del Abandono de Clientes (*Churn*) constituye un pilar fundamental en la estrategia de negocio del sector de las telecomunicaciones. Dada la madurez y la intensa competencia del mercado, la retención de clientes es financieramente superior a la adquisición, ya que esta última conlleva costos significativamente más altos. El *Churn*, entendido como la pérdida de usuarios, no solo implica una disminución directa en los ingresos, sino que también sirve como un indicador de fallas sistémicas en la calidad del servicio o la propuesta de valor. La literatura académica subraya que la clave está en migrar de una gestión reactiva a una intervención proactiva, identificando la probabilidad de abandono con suficiente antelación.

La herramienta metodológica central para esta proactividad es la Predicción de Abandono (*Churn Prediction*), una tarea de clasificación dentro de la Minería de Datos que emplea el Aprendizaje Automático (Machine Learning). Los modelos se entrenan a partir de datos históricos etiquetados para predecir si un cliente activo se clasificará como "Abandona" en un periodo futuro. El desarrollo de estos modelos requiere de metodologías estandarizadas (como CRISP-DM o SEMMA) para garantizar la robustez del proceso, desde la limpieza y la ingeniería de características hasta la evaluación final del rendimiento.

Los trabajos de investigación en este campo comparan consistentemente la eficacia de varios algoritmos de clasificación. La Regresión Logística se utiliza a menudo como un modelo de línea base por su sencillez y alta interpretabilidad, permitiendo entender la dirección y la magnitud de la influencia de cada variable. Por otro lado, las Redes Neuronales Artificiales (RNA), especialmente en configuraciones profundas, demuestran una gran capacidad para modelar relaciones no lineales y complejas en los datos, alcanzando altos niveles de precisión, como se observa en la aplicación de optimizadores avanzados en el trabajo de Pinto y Gutiérrez

(2023). Finalmente, los modelos basados en árboles, como Random Forest y las técnicas de Boosting (e.g., XGBoost), son esenciales. *Random Forest* es valorado por su estabilidad y su capacidad para mitigar el sobreajuste (*overfitting*), mientras que las técnicas de *Boosting* suelen reportar el mayor rendimiento predictivo en la clasificación de *Churn*, convirtiéndose en un punto de referencia clave para la comparación.

El rendimiento de cualquier algoritmo depende intrínsecamente de la calidad de las Variables Predictivas (*Features*) utilizadas. Las variables cruciales analizadas en la documentación se categorizan en: Variables Contractuales (como la duración del contrato o el tipo de facturación), Variables de Uso (consumo de datos, minutos) y Variables Demográficas. El análisis de la importancia de las variables es fundamental, ya que permite a la empresa no solo predecir el abandono, sino también entender las causas subyacentes del riesgo, lo cual informa la estrategia de retención.

Finalmente, la Predicción de Abandono solo genera valor cuando se traduce en una acción de negocio eficiente. El resultado del modelo, es decir, la probabilidad de abandono debe ser filtrado estratégicamente. Por ello, la Segmentación de Clientes (*Clustering*) se establece como la estrategia crucial post-predicción. El trabajo de Alegre (2020) resalta que el *Clustering* (por ejemplo, con K-means) permite agrupar a los clientes según su valor o comportamiento. De esta forma, la empresa puede priorizar las acciones de retención e invertir recursos significativos solo en aquellos clientes en alto riesgo que, además, pertenecen a segmentos rentables o estratégicos, garantizando que la intervención proactiva sea costo-efectiva.

## **Metodología**

La metodología de esta monografía se basa en un enfoque de investigación cualitativa-analítica y se sustenta en una revisión sistemática de literatura de fuentes primarias y secundarias. El propósito es construir un marco estratégico justificado sobre la predicción de abandono de clientes, sin recurrir a la implementación o desarrollo de nuevos modelos de Aprendizaje Automático (ML).

### **Tipo de Investigación**

El trabajo se define como una monografía de revisión y análisis comparativo. La investigación no incluye trabajo de campo ni la manipulación de variables, sino que se centra en la interpretación, síntesis y crítica de las metodologías, resultados y conclusiones obtenidas en trabajos de investigación y artículos científicos. Esto permite validar y contrastar la información con el objetivo de justificar las mejores prácticas.

### **Fuentes de Información**

La revisión documental se soporta en dos tipos de fuentes: (i) fuentes primarias (casos de estudio) y (ii) fuentes secundarias (artículos científicos y guías metodológicas).

- Fuentes primarias (casos de estudio): los tres trabajos de especialización/tesis seleccionados como núcleo comparativo (Alegre, 2020; Falla Arango, 2021; Pinto & Gutiérrez, 2023).

- Fuentes secundarias: literatura académica (2020 en adelante) y trabajos aplicados que complementan el núcleo comparativo, incluyendo estudios con datasets Telco (IBM y datos reales) y revisiones sistemáticas/bibliométricas. Se incluyen, entre otros: Castro Rodríguez y Pérez Vázquez (2020); Zepeda Castillo, Castro Sánchez y Acuña Valverde (2024); Santamaría Guzmán (2024); Candela Sevilla (2025) y Castillo Sánchez (2025). Adicionalmente, se adopta

PRISMA 2020 como guía de reporte para transparentar el proceso de búsqueda y selección (Page et al., 2021).

Estas fuentes se consolidan en una matriz de trazabilidad (registro de búsqueda/selección) y se resumen en la Tabla 2 del apartado de Resultados.

### **Estrategia de Búsqueda**

Se definió una estrategia de búsqueda estructurada con ventana temporal 2020–2025, en español e inglés, orientada a recuperar literatura sobre predicción de churn en telecomunicaciones mediante ML/DL, así como literatura sobre variables determinantes del churn y enfoques de explicabilidad (XAI).

- Bases de datos y repositorios sugeridos (según disponibilidad institucional): Scopus, IEEE Xplore, ScienceDirect, SpringerLink, ACM Digital Library y repositorios universitarios (Biblioteca Virtual UNAD, repositorios institucionales). Complementariamente, se consideró arXiv y Google Scholar para ampliar cobertura y verificar textos completos, siguiendo prácticas reportadas en revisiones recientes (Candela Sevilla, 2025; Castillo Sánchez, 2025).

- Cadenas de búsqueda (ejemplos):

- En inglés: ("telecom\*" OR "telecommunication\*") AND ("customer churn" OR churn OR "customer retention" OR "customer abandonment") AND ("machine learning" OR "deep learning" OR "random forest" OR "xgboost" OR "neural network" OR "ensemble") AND (prediction OR classification).

- En español: (telecomunicaciones OR telco) AND (abandono OR deserción OR fuga OR churn) AND ("aprendizaje automático" OR "machine learning" OR "redes neuronales" OR "random forest" OR ensamble) AND (predicción OR clasificación).

- Filtros aplicados: año de publicación  $\geq 2020$ ; tipo de documento (artículo científico, capítulo, conferencia, tesis/monografía institucional relevante); área temática (ciencia de datos/análítica, sistemas de información, telecomunicaciones, minería de datos); idioma (español/inglés).

### **Criterios de Inclusión**

- Publicaciones entre 2020 y 2025 (inclusive).
- Estudios aplicados al sector telecomunicaciones o a datasets Telco, o estudios generales de churn con sección explícita para telecom.
- Uso explícito de técnicas de ML/DL para clasificación/predicción de churn (p. ej., Regresión Logística, Árboles, Random Forest, XGBoost/boosting, SVM, RNA).
- Reportan métricas de evaluación (al menos una de: Accuracy, Precision, Recall/Sensibilidad, F1, AUC-ROC).
- Describen variables/atributos utilizados (contractuales, uso/consumo, facturación, demográficas) o análisis de importancia de variables/XAI.

### **Criterios de Exclusión**

- Publicaciones antes de 2020 (salvo marcos teóricos clásicos estrictamente necesarios y debidamente justificados).
- Estudios sin relación con churn (p. ej., predicción de demanda, fraude, etc.).
- Trabajos sin descripción mínima del método (algoritmo, datos, variables) o sin resultados evaluables.
- Documentos no académicos o sin revisión por pares cuando existan alternativas de mayor calidad (p. ej., entradas de blog sin respaldo).

- Estudios cuyo foco sea churn en sectores distintos sin posibilidad de extrapolación a telecom (si no discuten variables/arquitecturas aplicables).

### **Proceso de Selección y Registro**

El proceso de selección se documentó siguiendo una adaptación de PRISMA 2020 para revisiones de literatura (Page et al., 2021). En términos operativos, se aplicaron cuatro etapas: La Figura 1 presenta una plantilla del diagrama de flujo PRISMA 2020 para registrar los conteos del proceso de selección.

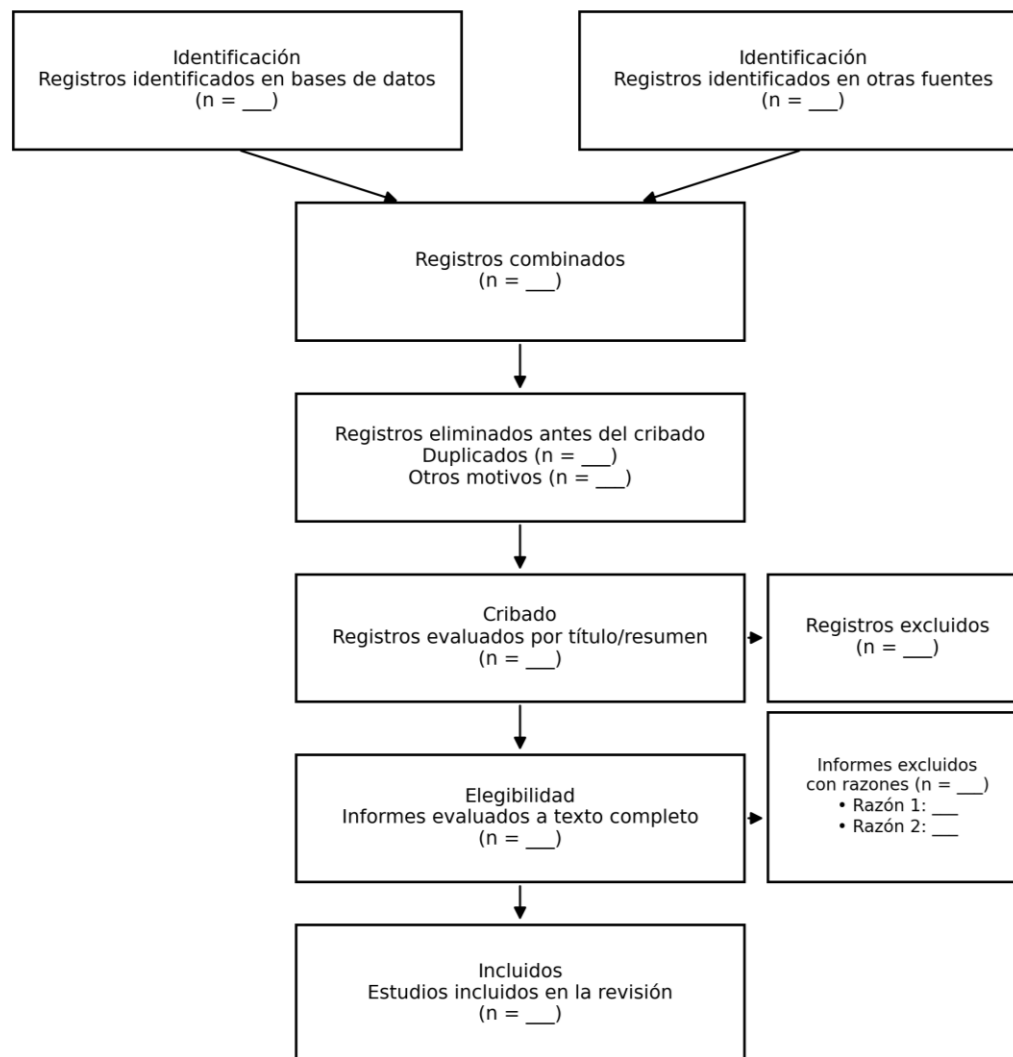
- 1. Identificación: ejecución de ecuaciones en las fuentes seleccionadas y exportación de resultados a una matriz de registro.
- 2. Depuración: eliminación de duplicados y registros incompletos.
- 3. Cribado (screening): lectura de título/resumen para verificar pertinencia respecto a Churn Prediction en Telco y ML.
- 4. Elegibilidad e inclusión: lectura de texto completo y aplicación final de criterios de inclusión/exclusión.

Nota: para fines de auditoría académica, se recomienda anexar la matriz de búsqueda/selección (con campos: fuente, ecuación, fecha, título, decisión y motivo de exclusión) como apéndice o entregable adicional.

**Figura 1**

*Diagrama de Flujo PRISMA 2020 (Plantilla para Registrar el Proceso de Selección)*

**Diagrama de flujo PRISMA 2020 (plantilla)**



**Criterios de Extracción y Síntesis de Datos**

De cada estudio incluido (primario o secundario) se extrajeron datos de forma estandarizada para permitir comparación homogénea. Los campos mínimos definidos fueron:

- Referencia bibliográfica completa (autor, año, tipo de documento).

- Contexto: país/operador o tipo de servicio (móvil/fijo/paquetes), y tipo de churn (voluntario/involuntario si se reporta).
- Datos: origen del dataset (público/privado), tamaño de muestra, periodo, balance de clases.
- Variables: categorías (contractuales, uso/consumo, facturación, demográficas, servicio/soporte) y variables más influyentes.
- Preparación de datos: tratamiento de faltantes, codificación, escalamiento, selección de variables, balanceo (SMOTE u otros si aplica).
- Modelos evaluados: algoritmos comparados y configuración general.
- Validación: partición train/test o validación cruzada; control de overfitting.
- Métricas: Accuracy, Precision, Recall, F1, AUC y matriz de confusión cuando se reporta.
- Hallazgos: mejor modelo y razones (rendimiento, interpretabilidad, estabilidad).
- Limitaciones y recomendaciones (p. ej., interpretabilidad, drift, disponibilidad de variables).

La síntesis final se realizó mediante comparación narrativa y tabulación (Tabla 1 y Tabla 2), priorizando convergencias metodológicas entre los tres casos de estudio y la literatura reciente (2020 en adelante).

### **Fases Metodológicas**

El desarrollo de la monografía se estructura en tres fases principales que permiten la integración del conocimiento especializado de diversas fuentes:

1. Revisión de Literatura y Contextualización Teórica (Fuentes Secundarias)

Esta fase consiste en la búsqueda y el análisis de artículos científicos, *papers* de repositorios académicos y literatura especializada.

- Objetivo: Establecer el Marco Teórico y el estado del arte de la predicción de *Churn* en telecomunicaciones. Se validan y definen los criterios de rendimiento de los modelos de clasificación (*accuracy, recall, AUC*), se identifican los algoritmos más frecuentemente empleados a nivel global y se contextualiza la importancia estratégica de las variables predictivas y las técnicas de segmentación (*Clustering*). Esta información sienta las bases para el análisis comparativo de los casos de estudio.

## 2. Análisis Crítico-Comparativo de Referentes Primarios

Esta fase se centra en la lectura profunda y detallada de los tres documentos de especialización proporcionados por el investigador, los cuales fungen como los casos de estudio principales:

- Referente 1: "Predicción de abandono de clientes en una empresa de telecomunicaciones" (Alegre, 2020).
- Referente 2: "ALGORITMO DE PREDICCIÓN DE ABANDONO DE CLIENTES DE SERVICIOS FIJOS EN TELECOMUNICACIONES BASADO EN UN CONJUNTO DE DATOS DE LA EMPRESA IBM" (Pinto & Gutiérrez, 2023).
- Referente 3: "PREDICCIÓN DE ABANDONO DE CLIENTES EN TELECOMUNICACIONES MEDIANTE EL APRENDIZAJE AUTOMÁTICO" (Falla Arango, 2021).

Se realiza una extracción y confrontación de datos clave en función de los objetivos específicos: algoritmos utilizados (Redes Neuronales, Random Forest, Regresión Logística), variables con mayor poder predictivo y métricas de rendimiento reportadas en cada estudio.

### 3. Síntesis, Evaluación Estratégica y Conclusiones

En esta fase, los hallazgos del análisis comparativo se sintetizan y se evalúan para construir el cuerpo argumentativo final. El proceso incluye:

- **Justificación de Metodologías:** Se compara el rendimiento de los algoritmos y se justifica su idoneidad basándose en la precisión reportada y la complejidad del modelo.
- **Análisis Estratégico Post-Predicción:** Se analiza y describe la necesidad de integrar la predicción con la Segmentación de Clientes para asegurar que las acciones de retención sean costo-efectivas y enfocadas a los clientes estratégicos.
- **Elaboración Documental:** Se organiza la información en los capítulos temáticos y se redactan las conclusiones, asegurando que respondan de forma directa y justificada a la Pregunta Central y a los Objetivos Específicos del trabajo.

#### **Criterio de Análisis**

El principal criterio es la validez y la coherencia metodológica de todas las fuentes revisadas. La solidez del argumento de la monografía se basa en la capacidad de interpretar, contrastar y sintetizar los resultados publicados, focalizando la discusión en la aplicabilidad práctica y la justificación estratégica de las metodologías de Aprendizaje Automático en la gestión proactiva de clientes de telecomunicaciones.

## Resultados

Los resultados que se presentan a continuación provienen de la síntesis e interpretación rigurosa de los hallazgos y conclusiones reportados en los trabajos de especialización analizados. Estos resultados se agrupan para ofrecer una justificación estratégica sobre las mejores prácticas metodológicas en la Predicción de Abandono de Clientes (*Churn Prediction*) dentro del sector de las telecomunicaciones.

### Eficacia y Rendimiento de los Algoritmos de Clasificación

El análisis comparativo de los modelos de Aprendizaje Automático (ML), tal como se implementan en los referentes, demuestra una jerarquía clara en términos de capacidad predictiva.

#### 1. Superioridad de Modelos Complejos (RNA y Ensamble)

Existe un consenso metodológico en que los modelos avanzados, capaces de capturar relaciones no lineales entre las variables, superan consistentemente a los modelos estadísticos lineales:

Redes Neuronales Artificiales (RNA): Pinto y Gutiérrez (2023) implementan una RNA con ajustes de hiperparámetros y optimizadores (p. ej., Nadam) sobre un dataset Telco (IBM). En su evaluación reportan un desempeño alto: Accuracy=0,96872; Precisión=0,912014; Recall=0,974684; F1=0,942308 y AUROC=0,970643. Estos resultados sugieren que, bajo un preprocesamiento adecuado y optimización, las RNA pueden maximizar la capacidad de discriminación (AUC) y la detección de clientes con riesgo (Recall).

Modelos basados en árboles y ensambles (Random Forest, Gradient Boosting, XGBoost, LightGBM): La evidencia revisada muestra que los métodos de ensamble y boosting se mantienen como alternativas muy competitivas para datos tabulares de telecomunicaciones. En el

caso de Falla Arango (2021), XGBoost se reporta como el algoritmo con mejor desempeño global (AUROC=0,7854; Accuracy=0,791). En Alegre (2020) destacan modelos ensamblados con tasa de fallo  $\approx 0,147$  y AUROC  $\approx 0,910$ , así como un Random Forest con Accuracy  $\approx 0,8455$ . En datos reales a gran escala, Santamaría Guzmán (2024) muestra que LightGBM y XGBoost alcanzan Accuracy  $\approx 0,87$  con AUROC  $\approx 0,864$ , con tiempos de entrenamiento inferiores a TabNet. Asimismo, Zepeda Castillo et al. (2024) reportan que Random Forest logra el menor error (19,55%) con AUC=70,85% en su comparativa.

## 2. El Rol del Modelo Base (Regresión Logística)

La Regresión Logística se utiliza en todos los referentes como modelo de línea base para la comparación. El resultado muestra que, si bien su rendimiento en métricas de clasificación pura es inferior a las RNA y *Random Forest*, su valor radica en la interpretabilidad de los coeficientes. Este modelo permite a la gerencia y a los analistas justificar la dirección del impacto de cada variable sobre el *Churn* de una manera transparente, lo cual es esencial para construir confianza en el modelo y validar la teoría subyacente al negocio.

Complementariamente, Santamaría Guzmán (2024) evidencia un trade-off relevante: TabNet maximiza la sensibilidad (0,744) frente a LightGBM (0,736) y XGBoost (0,695), pero a costa de mayor tiempo de entrenamiento ( $\approx 38,55$  min vs  $\approx 15,33$ – $15,79$  min). Este tipo de hallazgo es clave cuando el objetivo de negocio prioriza no “dejar escapar” clientes en riesgo (Recall) más que optimizar únicamente la exactitud global (Accuracy).

También se observa que modelos clásicos pueden mantener desempeño competitivo en ciertos escenarios: Castro Rodríguez y Pérez Vázquez (2020) reportan que, en su ranking, un modelo SVM alcanza Accuracy<sub>test</sub>=0,8043 (aunque con Recall<sub>test</sub>=0,4957), lo que sugiere

que la selección del modelo debe alinearse con la métrica crítica del negocio (p. ej., Recall/Sensibilidad en churn) y con los costos asociados a falsos positivos/negativos.

### **Identificación y Justificación de Variables Predictivas Clave**

Los resultados de la Ingeniería de Características en los referentes confirman que el comportamiento contractual y de uso tiene un poder predictivo muy superior a las variables demográficas tradicionales.

Factores Contractuales como Principales Predictores: La Antigüedad del Cliente (*Tenure*) y el Tipo de Contrato emergen como las variables más influyentes de forma transversal. Los análisis de la importancia de variables demuestran que:

Baja Antigüedad: Los clientes con menor tiempo de permanencia (*Tenure* bajo) son sistemáticamente clasificados con un riesgo de abandono mucho mayor (Alegre, 2020).

Contrato Mensual: Los clientes con contratos de corta duración (mensuales) presentan una flexibilidad que se traduce en mayor riesgo, a diferencia de aquellos con contratos anuales o bianuales que actúan como barreras al cambio o *lock-in*.

Servicios asociados a Internet y seguridad: Variables como Seguridad en línea (OnlineSecurity) y el tipo/uso de servicio de Internet aparecen como determinantes en análisis recientes; su ausencia o baja adopción puede asociarse a mayor probabilidad de churn (Zepeda Castillo et al., 2024).

Cargos totales y mensuales: Los montos facturados (Cargos mensuales/total) reflejan nivel de consumo y percepción de valor; cambios o montos altos pueden correlacionarse con insatisfacción y riesgo de abandono (Alegre, 2020; Falla Arango, 2021).

Variables de Pagos y Consumo: Otras variables con alto poder predictivo son los Cargos Mensuales y la Forma de Pago. El uso de métodos de pago automático o facturación sin papel (o

la ausencia de ellos) actúa como un fuerte indicador del nivel de vinculación y satisfacción del cliente.

Servicios Adicionales: La adición de múltiples servicios (línea secundaria, soporte técnico *premium*, etc.) reduce la probabilidad de *Churn*. Este resultado indica que la diversificación del portafolio contratado por el cliente genera una mayor dependencia del proveedor, lo que se traduce en una mayor dificultad para migrar a la competencia.

### **El Resultado Estratégico: Integración de Predicción y Segmentación**

El resultado más significativo para la toma de decisiones gerenciales es la validación de la estrategia post-predicción. El modelo de ML proporciona una lista de clientes en riesgo (probabilidad de *Churn* alta), pero la aplicación indiscriminada de costosas campañas de retención a todos ellos puede mermar la rentabilidad.

Necesidad de Segmentación: El trabajo de Alegre (2020) evidencia que el resultado estratégico de la predicción debe combinarse con el valor del cliente. Para ello, se utiliza el Clustering (e.g., K-Means), el cual segmenta a la base de clientes según su rentabilidad y comportamiento pasado.

Priorización Costo-Efectiva: El resultado final del análisis no es solo el modelo, sino la matriz de decisión que prioriza la intervención. El modelo de predicción identifica el *riesgo*, mientras que la segmentación identifica el *valor*. Por lo tanto, la acción de retención es óptima y financieramente justificada solo cuando se dirige a clientes que cumplen con el doble criterio: ALTA PROBABILIDAD DE ABANDONO (predicción) y ALTO VALOR DE VIDA DEL CLIENTE (segmentación). Este resultado transforma el análisis de datos en una ventaja competitiva tangible.

### Síntesis de Evidencia Complementaria (2020–2025)

Además de los tres referentes primarios, se incorporaron cinco documentos recientes que amplían la comparación hacia modelos adicionales (SVM, LightGBM, TabNet), estudios a gran escala y revisiones sistemáticas/bibliométricas.

Candela Sevilla (2025) presenta una revisión bibliométrica/cienciométrica (2020–2025) que reporta tendencias en el uso de técnicas de balanceo de clases (SMOTE/ADASYN) y crecimiento de enfoques de explicabilidad (XAI) para facilitar adopción en negocio.

Castillo Sánchez (2025) desarrolla una revisión sistemática (PRISMA) enfocada en modelos de analítica avanzada para churn telco; su síntesis refuerza la predominancia de ensamblados basados en árboles y la necesidad de buenas prácticas de reporte, comparabilidad y trazabilidad.

Zepeda Castillo et al. (2024) concluyen que Random Forest obtiene el menor error (19,55%) y  $AUC=70,85\%$ , y destacan variables influyentes como contrato, tenure, cargos totales/mensuales y seguridad en línea.

Santamaría Guzmán (2024) compara TabNet vs XGBoost vs LightGBM en datos reales altamente desbalanceados ( $\approx 2,8\%$  churn). Reporta que TabNet logra la mayor sensibilidad (0,744) pero con mayor tiempo de entrenamiento, mientras LightGBM maximiza la exactitud ( $\approx 0,87$ ) con  $AUROC \approx 0,864$ .

Castro Rodríguez y Pérez Vázquez (2020) comparan cuatro modelos (Regresión Logística, Random Forest, XGBoost y SVM) sobre un dataset Telco. Su ranking muestra un SVM con el mayor  $Accuracy\_test$  (0,8043), mientras que la Regresión Logística alcanza el mejor  $F1\_test$  (0,5996), evidenciando que la elección depende de la métrica objetivo.

**Tabla 1***Resultados del Análisis Comparativo de Referentes*

Eje de Análisis	Referente 1: Alegre (2020)	Referente 2: Pinto & Gutiérrez (2023)	Referente 3: Falla Arango (2021)
Algoritmo de Mayor Rendimiento	Ensamble (stacking) y métodos de boosting (GBM/XGBoost). Reporta modelos ensamblados con tasa de fallo $\approx 0,147$ y AUROC $\approx 0,910$ ; y un Random Forest (rf4) con Accuracy $\approx 0,8455$ .	Redes Neuronales Artificiales (RNA). El modelo final reporta Accuracy=0,96872 y AUROC=0,970643 (con Recall=0,974684 y F1=0,942308).	XGBoost. Fue el algoritmo con mejor desempeño global y menor cantidad de falsos positivos/negativos; reporta AUROC=0,7854 y Accuracy=0,791.
Variables Predictivas Clave	Tenure (antigüedad), tipo de contrato, cargos mensuales y totales. Integra además segmentación (clustering) para priorizar clientes de alto valor.	Variables de contrato y permanencia; cargos/consumo; y servicios adicionales (p. ej., soporte/seguridad/servicios complementarios).	Tenure, tipo de contrato, cargos mensuales y cargos totales; y variables asociadas a servicios (p. ej., InternetService/servicios adicionales).
Principal Objetivo del Modelo	Rentabilidad de la Retención. Predecir el riesgo para luego priorizar la acción	Máxima Precisión Predictiva. Enfocado en optimizar el algoritmo para lograr la mejor métrica de clasificación posible.	Comparación y selección de modelos. Determinar el algoritmo de ML con mejor capacidad predictiva para churn en

Eje de Análisis	Referente 1: Alegre (2020)	Referente 2: Pinto & Gutiérrez (2023)	Referente 3: Falla Arango (2021)
	sobre segmentos de alto valor.		telecom (con base en AUC/Accuracy y errores).
Estrategia Post-Predicción	Segmentación ( <i>Clustering</i> K-Means). Es el resultado clave para la toma de decisiones costo-efectivas.	Clasificación Directa. La estrategia se centra en la alta fidelidad del modelo para identificar al cliente de riesgo.	Clasificación Directa. La estrategia se centra en la efectividad del modelo de predicción.

El análisis de la monografía se fundamenta en un corpus documental mixto, compuesto por tres trabajos de especialización que constituyen los casos de estudio principales y una literatura científica externa de apoyo. Los referentes primarios proveen datos específicos sobre la aplicación práctica del Aprendizaje Automático (ML) en la predicción de abandono de clientes, la comparación de algoritmos (Regresión Logística, Redes Neuronales, Random Forest) y la evaluación de las variables predictivas. La literatura secundaria y los artículos científicos complementan este análisis, proporcionando el contexto teórico y estadístico necesario para contrastar y validar los resultados de rendimiento y las estrategias post-predicción, como el uso de la Segmentación (*Clustering*) para asegurar la rentabilidad de las acciones de retención. La siguiente tabla resume las fuentes utilizadas, diferenciando los referentes primarios (casos de estudio centrales) de la literatura secundaria que sirve de apoyo para el marco teórico y la validación de los resultados.

**Tabla 2***Fuentes de Análisis de la Monografía*

Título del Documento	Autor(es)	Año	Tipo de Fuente	Aporte Clave a la Monografía
Predicción de abandono de clientes en una empresa de telecomunicaciones	Federico Alegre	2020	Referente Primario (TFM)	Justificación de la Segmentación ( <i>Clustering</i> K-Means) como estrategia crucial post-predicción para la priorización rentable.
ALGORITMO DE PREDICCIÓN DE ABANDONO DE CLIENTES DE SERVICIOS FIJOS EN TELECOMUNICACIONES.	Pinto & Gutiérrez	2023	Referente Primario (Monografía)	Análisis detallado y aplicación de Redes Neuronales Artificiales (RNA), centrado en la consecución de alta precisión.
..				
PREDICCIÓN DE ABANDONO DE CLIENTES EN TELECOMUNICACIONES MEDIANTE EL APRENDIZAJE AUTOMÁTICO	Jesús D. Falla Arango	2021	Referente Primario (Tesis)	Aplica CRISP-DM y compara modelos de clasificación; reporta a XGBoost como mejor desempeño global (AUROC=0,7854; Accuracy=0,791) y discute variables con mayor poder predictivo.
The PRISMA 2020 statement: An updated guideline for reporting systematic reviews	Page, McKenzie, Bossuyt, et al.	2021	Guía metodológica (reporte de revisiones)	Estandariza el reporte de búsqueda, selección, inclusión/exclusión y flujo de registros; guía la

Título del Documento	Autor(es)	Año	Tipo de Fuente	Aporte Clave a la Monografía
Evaluación del abandono de clientes de una compañía de telecomunicaciones por medio de cuatro modelos de aprendizaje máquina	Jorge Octavio Castro Rodríguez; Ernesto Pérez Vázquez	2020	Artículo científico	transparencia y reproducibilidad de la revisión documental. Compara Regresión Logística, Random Forest, XGBoost y SVM en dataset Telco (IBM); presenta ranking de desempeño y discusión metodológica (train/test 70/30 y validación cruzada k=10).
Modelo de clasificación con algoritmo TabNet para abandono de clientes en servicios de telecomunicaciones del Instituto Costarricense de Electricidad entre agosto y octubre de 2022	Patrick José Santamaría Guzmán	2024	Tesis / Trabajo final de investigación aplicada (Maestría)	Compara TabNet vs XGBoost vs LightGBM en datos reales (millones de registros); discute desbalance severo, preprocesamiento y trade-off entre sensibilidad y tiempo de entrenamiento.
Abandono de clientes en telecomunicaciones: Un enfoque de clasificación	Abigail Zepeda Castillo; Kiara Castro Sánchez; Kristel Acuña Valverde	2024	Documento académico (UCR)	Evalúa técnicas de clasificación; concluye que Random Forest es la técnica más efectiva (error 19,55% y AUC 70,85%) e identifica variables influyentes (contrato, tenure, cargos y seguridad en línea).

Título del Documento	Autor(es)	Año	Tipo de Fuente	Aporte Clave a la Monografía
Modelos de analítica avanzada y aprendizaje automático para la predicción de abandono de clientes en el sector de telecomunicaciones: revisión sistemática (PRISMA)	Hugo Alexander Castillo Sánchez	2025	Monografía (UNAD) / Revisión sistemática	Aporta guía metodológica y síntesis de evidencia 2020+ bajo PRISMA; resume algoritmos usados, variables y desafíos (calidad, escalabilidad, interpretabilidad y ética). Presenta revisión bibliométrica/cienciométrica con protocolo PRISMA; recupera 60 artículos (2020–2025) y reporta tendencias como balanceo (SMOTE/ADASYN) y adopción de XAI para interpretabilidad.
Modelos de clasificación basados en machine learning (revisión bibliométrica y cienciométrica 2020–2025)	Candela Sevilla, M. G.	2025	Artículo de revisión	

## Conclusiones

Las conclusiones de esta monografía, derivadas del análisis comparativo de los referentes especializados, ofrecen un marco estratégico sólido y justificado para la aplicación del Aprendizaje Automático (ML) en la gestión proactiva del Abandono de Clientes (*Churn*) en el sector de las telecomunicaciones.

La investigación concluye que, para maximizar la capacidad predictiva en churn telco, es recomendable priorizar modelos no lineales y enfoques de ensamble/boosting. Los referentes muestran que las RNA pueden alcanzar desempeños altos cuando se optimizan y se preparan adecuadamente los datos (Pinto & Gutiérrez, 2023), y que los ensambles basados en árboles (Random Forest, XGBoost, LightGBM) presentan robustez y buen desempeño en datos tabulares (Alegre, 2020; Falla Arango, 2021; Santamaría Guzmán, 2024). No obstante, la selección del modelo debe alinearse con la métrica crítica del negocio (en churn suele priorizarse Recall/Sensibilidad) y con el costo de errores; por ejemplo, Castro Rodríguez y Pérez Vázquez (2020) muestran que un SVM puede maximizar Accuracy, mientras TabNet puede mejorar Sensibilidad a costa de mayor cómputo (Santamaría Guzmán, 2024).

Se confirma que el riesgo de abandono está directamente relacionado con el nivel de vinculación contractual y de uso, y no primariamente a factores demográficos. La variable más crítica es la Antigüedad del Cliente (*Tenure*), seguida por el Tipo de Contrato (mensual vs. anual). Los clientes con baja permanencia o contratos flexibles presentan el mayor riesgo, lo que justifica concentrar los esfuerzos de retención en estos segmentos vulnerables. Además, el número de Servicios Adicionales contratados funciona como una barrera de salida (*lock-in*), reduciendo la probabilidad de *Churn*.

Finalmente, la conclusión más importante para la toma de decisiones gerenciales es la necesidad de integrar la predicción con la estrategia de valor. Se concluye que la acción de retención es óptima y financieramente justificable solo cuando se aplica la Segmentación de Clientes (*Clustering*) (Alegre, 2020). El resultado final de la monografía es que la intervención debe priorizarse únicamente en aquellos clientes clasificados con ALTA PROBABILIDAD DE ABANDONO que, simultáneamente, pertenecen a segmentos de ALTO VALOR o rentabilidad para la compañía, transformando el análisis predictivo en una ventaja competitiva tangible.

### Referencias Bibliográficas

- Alegre, F. (2020). Predicción de abandono de clientes en una empresa de telecomunicaciones (Trabajo de Fin de Máster, Máster en Minería de Datos e Inteligencia de Negocios, Facultad de Estudios Estadísticos).
- Candela Sevilla, M. G. (2025). Modelos de clasificación basados en machine learning. Rev. Peru. Ing. Arquit. Medio Ambient., 2(2). <https://doi.org/10.37711/repiana.2025.2.2.4>
- Castillo Sánchez, H. A. (2025). Modelos de analítica avanzada y aprendizaje automático para la predicción de abandono de clientes en el sector de telecomunicaciones: revisión sistemática (PRISMA) (Monografía de grado). Universidad Nacional Abierta y a Distancia (UNAD).
- Castro Rodríguez, J. O., & Pérez Vázquez, E. (2020). Evaluación del abandono de clientes de una compañía de telecomunicaciones por medio de cuatro modelos de aprendizaje máquina. *Research in Computing Science*, 149(8), 611–624.
- Falla Arango, J. D. (2021). Predicción de abandono de clientes en telecomunicaciones mediante el aprendizaje automático (Trabajo de grado de maestría). Universidad Jorge Tadeo Lozano.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Pinto Marcelo, Y. M., & Gutiérrez Ramírez, N. (2023). Algoritmo de predicción de abandono de clientes de servicios fijos en telecomunicaciones basado en un conjunto de datos de la empresa IBM. Universidad Distrital Francisco José de Caldas.

Santamaría Guzmán, P. J. (2024). Modelo de clasificación con algoritmo TabNet para abandono de clientes en servicios de telecomunicaciones del Instituto Costarricense de Electricidad entre agosto y octubre de 2022 (Trabajo final de investigación aplicada, Maestría Profesional en Estadística). Universidad de Costa Rica.

Zepeda Castillo, A., Castro Sánchez, K., & Acuña Valverde, K. (2024). Abandono de clientes en telecomunicaciones: Un enfoque de clasificación (Documento académico). Universidad de Costa Rica.

## Apéndices

### Apéndice A

#### *Especificaciones Técnicas de Algoritmos Analizados*

Esta sección detalla los parámetros de configuración de los algoritmos de Aprendizaje Automático (ML), en particular la arquitectura de la Red Neuronal Artificial (RNA), que fue crucial para alcanzar la alta precisión en el Referente 2.

#### **Arquitectura Detallada de la Red Neuronal Artificial (RNA)**

Elemento Técnico	Configuración y Valor (Pinto & Gutiérrez, 2023)	Justificación Metodológica
Tipo de Arquitectura	Red Neuronal Densa (Sequential Model)	Arquitectura clásica para tareas de clasificación binaria (Churn/No Churn).
Capas Ocultas	Tres capas densas (240, 220, 170 neuronas)	Uso de una arquitectura profunda para capturar relaciones no lineales y complejas en los datos.
Funciones de Activación	tanh (Capa 1), relu (Capa 2), ELU (Capa 3 y Salida)	Empleo de funciones de activación no lineales para añadir complejidad al modelo.
Capa de Salida	1 Neurona, activación ELU (para clasificación binaria)	Produce un valor de probabilidad que debe ser redondeado (0 o 1) para obtener la predicción final.
Optimizador	Nadam	Algoritmo de optimización que acelera la convergencia de la red, crucial para alcanzar la máxima precisión.

---

Pérdida ( <i>Loss</i> )	Error Cuadrático Medio (MSE)	Función utilizada para medir la diferencia entre la predicción y el valor real.
Épocas de Entrenamiento	70	Número de ciclos completos sobre el conjunto de datos de entrenamiento.

---

Nota técnica: En estudios complementarios también se reportan configuraciones y ajustes de hiperparámetros para modelos clásicos y de ensamble (p. ej., SVM con kernel RBF, Regresión Logística con penalización y XGBoost con parámetros como `colsample_bytree` y `gamma`), evidenciando que el ajuste fino puede cambiar el ranking de desempeño (Castro Rodríguez & Pérez Vázquez, 2020).

## Apéndice B

### *Métricas Detalladas de Rendimiento de Clasificación*

Esta tabla sintetiza rangos y valores representativos de métricas de rendimiento reportadas en los documentos seleccionados. En conjunto, refuerza la conclusión de que los enfoques no lineales (RNA), los ensambles/boosting basados en árboles (Random Forest, XGBoost, LightGBM) y modelos de deep learning para datos tabulares (TabNet) suelen ofrecer ventajas frente a modelos lineales cuando se optimiza el objetivo correcto (p. ej., Sensibilidad/Recall en churn).

### Comparativa de Rendimiento de Algoritmos de Clasificación

Métrica	Regresión Logística (Línea Base)	Random Forest (Ensamble)	Redes Neuronales (RNA)	Boosting (XGBoost/LightGBM)	TabNet (DL tabular)	Justificación Estratégica
Precisión ( <i>Accuracy</i> )	0,75 – 0,80	0,80 – 0,85	0,96 – 0,97	0,79 – 0,87	≈0,83	Identifica correctamente a los clientes que abandonan y que permanecen. La RNA busca maximizar esta métrica.
AUC (Área bajo la Curva)	≈0,76	0,71 – 0,78	≈0,97	0,78 – 0,86	≈0,862	Mide la capacidad de discriminación.

Métrica	Regresión Logística (Línea Base)	Random Forest (Ensamble)	Redes Neuronales (RNA)	Boosting (XGBoost/LightGBM)	TabNet (DL tabular)	Justificación Estratégica
Sensibilidad ( <i>Recall</i> )	≈0,53	≈0,50 – 0,51	≈0,97	≈0,69 – 0,74	≈0,744	<p>Selección del modelo. Valores superiores a 0.85 indican excelente rendimiento. Es la métrica más crítica en Churn: mide la capacidad de identificar correctamente a los clientes que realmente van a abandonar.</p>

### Contraste de la Matriz de Confusión (Síntesis)

El análisis de la matriz de confusión de los referentes revela que el principal problema de los modelos de línea base es el elevado número de Falsos Negativos (clientes que el modelo predice que NO abandonarán, pero sí lo hacen). Los modelos de RNA y Random Forest logran reducir

significativamente los Falsos Negativos, lo cual es la clave para una acción de retención proactiva exitosa.

## Apéndice C

### *Análisis de Importancia de Variables y Segmentación*

Esta sección presenta la evidencia de las variables predictivas más fuertes y la configuración de la estrategia de priorización post-predicción.

#### **Ranking de Variables con Mayor Poder Predictivo**

Categoría de Variable	Variable Clave	Impacto sobre la Probabilidad de Churn	Referentes que lo Confirman
Contractual	Antigüedad ( <i>Tenure</i> )	Negativo Fuerte: A mayor antigüedad, menor probabilidad de abandono.	Alegre (2020), Falla Arango (2021)
Contractual	Tipo de Contrato	Positivo Fuerte: Los contratos mensuales aumentan significativamente el riesgo.	Alegre (2020), Falla Arango (2021)
Financiera	Cargos Mensuales	Doble Impacto: Los cargos excesivamente altos o demasiado bajos indican riesgo.	Pinto & Gutiérrez (2023), Falla Arango (2021)
Servicio	Servicios Adicionales	Negativo: Más servicios contratados (TV, <i>streaming</i> ) reducen el riesgo por <i>lock-in</i> o dependencia.	Pinto & Gutiérrez (2023)

#### **C.2: Parámetros y Objetivo de la Segmentación (*Clustering*)**

La estrategia de Segmentación (*Clustering*) utilizada en el Referente 1 (Alegre, 2020) es vital para la justificación financiera de la retención.

### Parámetros y Objetivo Estratégico de la Segmentación (Clustering) Post-Predicción

Elemento de Segmentación	Parámetro/Resultado (Alegre, 2020)	Justificación Estratégica
Algoritmo de <i>Clustering</i>	K-Means	Algoritmo de Aprendizaje No Supervisado, eficiente para la agrupación de clientes.
Número Óptimo de <i>Clusters</i>	4	Determinado mediante técnicas de validación interna, buscando la mejor separación de grupos.
Resultado de Priorización	Matriz de Decisión (Riesgo vs. Valor del Cliente)	La acción de retención costosa solo se aplica al Cluster 1 (por ejemplo: "Clientes de Alto Riesgo con Alto Valor de Vida") para garantizar la rentabilidad de la inversión.