

**UNIVERSIDAD DE CHILE
FACULTAD DE MEDICINA
ESCUELA DE POSTGRADO
PROGRAMA DE GRADOS ACADÉMICOS**



**“PREDICCIÓN DE LA LEALTAD A LA INSTITUCIÓN DE
SALUD A PARTIR DE LA ATENCIÓN EN EL SERVICIO DE
URGENCIAS MEDIANTE EL USO DE TÉCNICAS DE
APRENDIZAJE DE MÁQUINAS”**

ÁLVARO LÓPEZ ACEVEDO

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN INFORMÁTICA MÉDICA

Director de Tesis: Prof. Dr. Eduardo Tobar A.

Co-Director de Tesis: Prof. Dr. Mauricio Cerda V.

2025

Agradecimientos

Tomo la oportunidad de agradecer por escrito a quienes participaron directa e indirectamente en este proyecto.

Este trabajo no habría sido posible sin la enorme colaboración del Profesor Mauricio Cerda, guía desde los inicios de este camino, desde el “Hola mundo” hasta los modelos de lenguaje. Leyó una y otra vez este texto, me preparó para las presentaciones con la comisión evaluadora y siempre tuvo la mejor disposición para darme una mano. Mauricio, gracias.

Agradecer también al Profesor Eduardo Tobar, quien, teniendo la responsabilidad de conducir un hospital como el HCUCH, me dedicó tantas horas de trabajo, reuniones, lectura y guía, siempre disponiendo alegremente tiempo para mí, siempre con una sonrisa y un consejo, aún con una agenda en la que no cabía una aguja. Mi admiración y reconocimiento para usted.

Mis compañeros, profesores y amigos del MIM, lugar en el que descubrí lo que quiero hacer por el resto de mi vida. Gracias por su amistad, consejo y humor.

Y a mi familia, recordatorio que el tiempo no existe, que somos eternos, que el mundo es perfecto y que los límites del Ser son una ilusión.

Resumen

La lealtad a la institución de salud se entiende como el compromiso sostenido de una persona con aquella institución de salud, reflejado en su decisión recurrente de regresar para recibir atención médica en la misma entidad. Este comportamiento no solo implica satisfacción con los servicios recibidos, sino también una preferencia activa por mantener el vínculo con la institución frente a otras opciones disponibles. Cultivar la lealtad usuaria afecta positivamente a la salud de usuarios y promueve la continuidad de estas organizaciones en el tiempo.

Los Servicios de Urgencias (SU) desempeñan un papel crucial en el fortalecimiento de la lealtad de los usuarios, ya que, con frecuencia, representan el primer punto de contacto del paciente con la institución y atienden a un gran volumen de personas. Sin embargo, desafíos como tiempos de espera prolongados, saturación del servicio (*Overcrowding*), abandono de pacientes sin ser atendidos y la estancia prolongada de pacientes (*Boarding*), entre otros, afectan negativamente la percepción de los usuarios hacia la institución, debilitando su confianza y satisfacción, con implicancias directas en su lealtad. Para diseñar políticas institucionales y estrategias comerciales costo-efectivas que promuevan y cultiven la lealtad, este proyecto de tesis se enfoca en la relación entre la atención en SU y la lealtad a la institución de salud.

A partir del Registro Clínico Electrónico del Hospital Clínico de la Universidad de Chile (HCUCH) se construyó un conjunto de datos de 140 354 atenciones de urgencia (2015-2019). Se generaron variables clínicas, demográficas y operacionales e implementaron cinco algoritmos de clasificación (XGBoost, Random Forest, LightGBM, Redes Neuronales y Regresión Logística con Elastic Net). El mejor desempeño se obtuvo con XGBoost: ROC AUC promedio 0,782.

Aunque la capacidad predictiva es moderada, el modelo ofrece un rendimiento sólido: identifica de forma confiable los predictores que mejor anticipan la lealtad y orienta dónde focalizar los esfuerzos estratégicos, a partir de una base de datos simple y extendida como es

el Dato de Atención de Urgencia (DAU), con una metodología de bajo costo y en un entorno de medición relevante para la institución.

Este trabajo, por tanto, subraya el valor de aprovechar los datos clínicos y operacionales generados en los SU, no solo para mejorar la atención individual, sino también como insumo estratégico para políticas de salud pública. Fortalecer su uso permite identificar patrones, anticipar riesgos y diseñar respuestas más equitativas, eficientes y sostenibles; además, el enfoque es potencialmente extensible a cualquier unidad que cuente con un DAU, convirtiéndolo en una herramienta práctica para la toma de decisiones a escala institucional.

Abstract

Loyalty to a healthcare institution is understood as a person's sustained commitment to that organization, reflected in their recurrent decision to return to the same facility for medical care. This behaviour involves not only satisfaction with the services received but also an active preference to maintain the bond with the institution over other available options. Cultivating user loyalty positively affects patients' health and promotes the long-term continuity of healthcare organisations.

Emergency Departments (EDs) play a crucial role in strengthening user loyalty because they often constitute the patient's first point of contact with the institution and handle a high volume of visits. However, challenges such as prolonged waiting times, overcrowding, patients who leave without being seen (LWBS) and extended boarding periods, among others, negatively affect users' perception of the institution, undermining their trust and satisfaction and, consequently, their loyalty. To design cost-effective institutional policies and commercial strategies that promote and cultivate loyalty, this thesis focuses on the relationship between ED care and loyalty to the healthcare institution.

Using the Electronic Health Record of the University of Chile Clinical Hospital (HCUCH), a dataset of 140,354 emergency visits (2015-2019) was built. Clinical, demographic and operational variables were engineered, and five classification algorithms were implemented (XGBoost, Random Forest, LightGBM, Neural Networks and Logistic Regression with Elastic Net). The best performance was achieved with XGBoost, with a mean ROC AUC of 0.782.

Although the predictive performance is moderate, the model delivers solid performance: it reliably identifies the predictors that best anticipate loyalty and indicates where to focus strategic efforts, drawing on a simple and widely available data source such as the Emergency Care Record (in Spanish "Dato de Atención de Urgencia", DAU), with a low-cost methodology and in a measurement environment highly relevant to the institution.

This work therefore underscores the value of leveraging the clinical and operational data generated in EDs, not only to improve individual care but also as a strategic input for public-health policy. Strengthening their use makes it possible to detect patterns, anticipate risks and design responses that are more equitable, efficient and sustainable; moreover, the approach is potentially extensible to any unit that maintains a DAU, making it a practical tool for decision-making at the institutional level.

Tabla de contenido

1.1.- Antecedentes del problema	10
1.1.1.- Servicios de Urgencia (SU).....	10
1.1.2.- Proceso de Atención de Urgencia Hospitalario.....	10
1.1.3.- Desafíos de los Servicios de Urgencia: <i>Overcrowding</i> , <i>LWBS</i> y <i>Boarding</i>	13
1.1.4.- Satisfacción y lealtad del paciente	15
1.1.5.- Satisfacción y lealtad a la institución a partir de la atención en SU.....	18
1.1.6.- Captura de Datos en SU	19
1.1.7.- Hospital Clínico de la Universidad de Chile (HCUCH)	20
1.2.- Aprendizaje de máquinas	22
1.2.1.- Preprocesamiento de Datos	24
1.2.2.- Selección y Entrenamiento del Modelo	26
1.2.3.- Evaluación del desempeño de los algoritmos implementados.....	28
1.2.4.- Aprendizaje de máquinas para el estudio de la lealtad.....	31
1.3.- Problema & Solución propuesta.....	36
2.- Hipótesis.....	37
3.- Objetivo General	37
4.- Objetivos específicos.....	37
5.- Materiales y Método.....	38
5.1.- Generar un conjunto de datos limpio, coherente y preprocesado a partir de la información almacenada en el sistema de información hospitalaria del HCUCH.	38
5.1.1.- Obtención de datos y Criterios de exclusión.....	38
5.1.2.- Variables a extraer.....	39
5.1.3.- Variable por predecir: Lealtad.....	39
5.1.4.- Análisis exploratorio y Preprocesamiento	40

5.2.- Implementación de algoritmos de Aprendizaje de Máquinas de clasificación y regresión para la predicción de lealtad a partir de los datos obtenidos.	43
5.3.- Medición y comparación el desempeño de los algoritmos implementados.	44
5.4.- Proponer estrategias y recomendaciones basadas en los hallazgos.....	45
6.- Resultados	47
6.1.- Generar un conjunto de datos limpio, coherente y preprocesado a partir de la información almacenada en el sistema de información hospitalaria del HCUCH.	47
6.1.1.- Obtención de datos y Criterios de exclusión.....	47
6.1.2.- Variables	48
6.1.3.- Preprocesamiento	49
6.1.4.- Análisis Descriptivo y Univariado	57
6.1.5.- Análisis de Multicolinealidad.....	62
6.2.- Implementación de algoritmos de Aprendizaje de Máquinas de clasificación y regresión para la predicción de lealtad a partir de los datos obtenidos.	63
6.2.1.- División del Conjunto de datos	63
6.2.2.- Selección de Características	63
6.2.3.- Ajuste de Hiperparámetros.....	65
6.3.- Medición y comparación el desempeño de los algoritmos implementados.	67
6.3.1.- Comparación curva ROC AUC de todos los algoritmos implementados	67
6.3.2.- Análisis de la estabilidad del desempeño con diferentes inicializaciones	68
6.3.3.- Detalles del desempeño del modelo de mejor rendimiento: XGBoost	69
6.4.- Identificación de las variables predictoras más importantes y proporcionar sugerencias basadas en estos hallazgos para promover la lealtad al establecimiento	70
6.4.1 Identificación de predictores relevantes	70
6.4.2 Estrategias y abordajes posibles para el cultivo de la lealtad institucional en función de los predictores.....	72

6.4.3 Estrategias y abordajes posibles para el cultivo de la lealtad institucional en función de la capacidad predictiva del modelo	73
7.- Discusión.....	74
7.1.- Análisis de diferencias con el estado del arte: Logros y limitaciones del proyecto	74
7.2.- Predictores dominantes: coincidencias y contrastes con la literatura	76
7.3.- Consideraciones éticas tanto en la medición como en el uso de la información .	77
7.4.- Alcances del proyecto: Oportunidades para la Salud Pública Chilena	78
8.- Conclusiones	79
9.- Bibliografía	81
ANEXOS.....	87
ANEXO 1. Variables Demográficas obtenidas a partir de la atención en SU.....	87
ANEXO 2. Variables Clínicas obtenidas a partir de la atención en SU.....	87
ANEXO 3. Variables Administrativas obtenidas a partir de la atención en SU.	88
ANEXO 4. Presencia de valores faltantes y atípicos en Variables Demográficas, junto con su manejo en caso de que corresponda.	88
ANEXO 5. Presencia de valores faltantes y atípicos en Variables Clínicas, junto con su manejo en caso de que corresponda.	89
ANEXO 6. Presencia de valores faltantes y atípicos en Variables Administrativas, junto con su manejo en caso de que corresponda.	90
ANEXO 7. Variables Demográficas. Análisis descriptivo y estadístico univariado.....	91
ANEXO 8. Variables Clínicas. Análisis descriptivo y estadístico univariado.	92
ANEXO 9. Variables Administrativas. Análisis descriptivo y estadístico univariado. ...	93
ANEXO 10. Matriz de Correlación entre variables predictoras.....	94
ANEXO 11. Hiperparámetros utilizados para cada modelo, definición e interpretación.	95
ANEXO 12. Hiperparámetros óptimos ajustados para cada modelo entrenado.....	96

1.- Introducción

1.1.- Antecedentes del problema

1.1.1.- Servicios de Urgencia (SU)

Los Servicios de Urgencia (SU) Hospitalarios son unidades especializadas cuyo propósito es proporcionar atención médica inmediata a situaciones clínicas de urgencia y emergencia, que requieren de diagnósticos, procedimientos y/o tratamientos en forma pronta y en breves lapsos de tiempo (1). En su conjunto, representan uno de los sectores hospitalarios de mayor demanda, con más de 20 millones de atenciones anuales en Chile (año 2023) y una amplia gama de pacientes y patologías, especialmente los de mayor riesgo de morbilidad (2). El sistema de salud chileno otorga atención de urgencia bajo los principios sanitarios de organización según nivel de complejidad y atención continua, 24 horas al día, los siete días de la semana (3).

1.1.2.- Proceso de Atención de Urgencia Hospitalario

El proceso de atención en un SU hospitalario se articula en función de actividades administrativas, clínicas y operacionales. Este proceso se desarrolla dentro de un área específicamente seleccionada dentro del hospital, la cual satisface una serie de requisitos funcionales, estructurales y logísticos para ejecutar sus actividades de manera eficiente y efectiva (4).

La atención de urgencia se activa a través de diversos canales de ingreso, que incluyen la demanda espontánea de los pacientes, la derivación por parte de otros profesionales de la salud, o situaciones de emergencia que surgen dentro del mismo establecimiento. A su llegada, es imperativo que cada paciente sea identificado y sometido a un proceso de categorización, triaje o *Triage* según su gravedad (Figura 1). En los SU hospitalarios, este proceso es llevado a cabo por un equipo de enfermería especializado. En función de las políticas del centro hospitalario, el modo de llegada y la gravedad del paciente. En esta etapa se genera el Dato de Atención de Urgencia (DAU) en el que, posteriormente, se registrará gran parte de las actividades realizadas durante la atención (4).




Figura 1. Inicio del proceso de atención de Urgencia hospitalario (4). El paciente inicialmente es admitido, generando el DAU, posteriormente es categorizado. Es un indicador de calidad que el tiempo desde admisión a categorización sea menor a 10 minutos. En caso en que la vida del paciente esté en riesgo se inicia reanimación y atención médica inmediata. En caso contrario el usuario debe esperar atención médica según su índice de severidad. Elaboración propia.

El Triage en Chile, se realiza empleando el *Emergency Severity Index* (ESI) según recomendación del MINSAL (3). El ESI es un algoritmo de clasificación que define cinco niveles de severidad (de C1 a C5), basados en el resultado de la evaluación clínica inicial del paciente. Por ejemplo, C1 denota la máxima severidad y requiere intervención y atención médica inmediata para resguardar la vida del paciente (Figura 2) (5).

Tras la atención médica inicial, el profesional tratante podrá decidir sobre la necesidad de intervenciones adicionales (evaluación por especialistas, realización de exámenes diagnósticos, procedimientos específicos), observación por un periodo breve para una reevaluación posterior, o bien el alta médica del paciente. La atención de urgencia finaliza con el Alta Médica y la definición de un destino específico para el paciente, que puede ser su domicilio, la hospitalización, el traslado a otra institución o, el fallecimiento. Este proceso termina con una actividad administrativa de egreso, que formaliza el cierre del Dato de Atención de Urgencia (DAU) (Figura 3). (4).

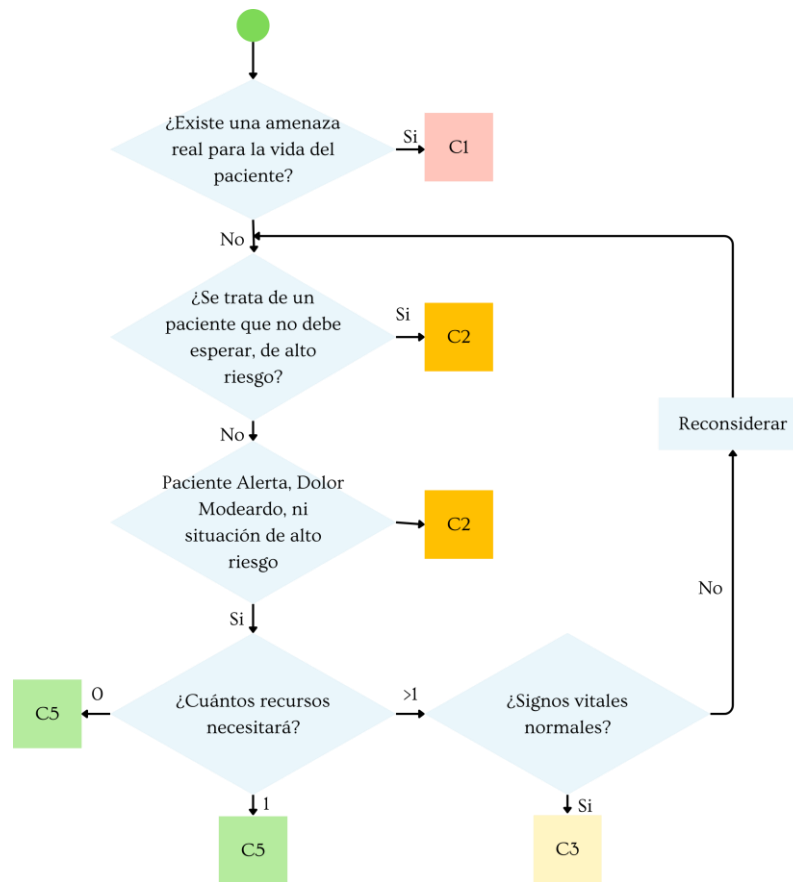


Figura 2. Algoritmo de categorización ESI (5). Todos los pacientes que son admitidos en un SU deben ser categorizados. El ESI está diseñado específicamente priorizar rápidamente a los pacientes graves, así como los que tienen mayor probabilidad de deteriorarse. Elaboración propia.




Figura 3. Cierre del proceso de atención de urgencia hospitalario (4). Durante el proceso de urgencia pueden realizarse múltiples actividades previo a Alta médica. Es un indicador de calidad que el proceso de urgencia no tome más de 6 horas hasta el Alta médica. Elaboración propia.

1.1.3.- Desafíos de los Servicios de Urgencia: *Overcrowding*, LWBS y *Boarding*

Si bien los SU se crean con la intención de proporcionar atención médica oportuna y eficaz, desde los años 80' se ha reportado progresivamente una importante saturación de la demanda de pacientes en estos servicios a lo largo de todo el mundo. Este fenómeno es conocido en inglés como *Overcrowding*, y es uno de los principales obstáculos para una atención de salud de alta calidad. Se define como el periodo de tiempo en que la demanda de los servicios de urgencia supera su capacidad de atención. Su causa principal es el exceso de pacientes que espera consulta, diagnóstico, tratamiento, transferencia o alta, generando desequilibrio entre la oferta y la demanda de servicio (1). El modelo de Asplin atribuye las causas del *Overcrowding* a una serie de factores que se clasifican en tres categorías (Figura 4): factores de entrada (*input*), de procesamiento (*throughput*) y de salida (*output*). Los factores de entrada incluyen el incremento sostenido en la demanda de consultas, la creciente complejidad de los casos atendidos, una proporción más elevada de adultos mayores con múltiples comorbilidades, y, el uso inapropiado de los servicios por parte de la población. En relación con los factores de procesamiento, se consideran las limitaciones de infraestructura, la escasez de personal capacitado y las ineficiencias en los procesos internos. Los factores de salida se refieren a la dificultad para dar de alta a los pacientes del SU, lo cual se debe frecuentemente a la falta de camas disponibles o a problemas en el proceso de traslado (1,6).




Figura 4. Modelo de Bret Asplin de las causas del *Overcrowding* (6). La vigencia de este modelo radica en que clasifica adecuadamente todos los aspectos que generan aumento de la demanda y mayor demora en la atención de pacientes. Elaboración propia.

El fenómeno de *Overcrowding* en los SU desata una serie de consecuencias. Uno de los efectos más importantes es conocido como el “Abandono Sin Atención Médica” (LWBS, por sus siglas en inglés *Left Without Being Seen*). Se define como el abandono del SU por parte del usuario previo a la atención médica. Su causa en la mayoría de los casos es por extensos tiempos de espera e influenciada además por factores sociodemográficos y el riesgo percibido del paciente (7–9). Si bien en países occidentales la incidencia de LWBS ronda el 10% de las consultas de urgencia (10), en contextos como el latinoamericano, esta cifra podría ser mayor debido a la sobrecarga asistencial. Este fenómeno, además, tiene consecuencias tangibles en la salud del paciente, según indica Johnson y Rowe, ya que cerca del 75% de los pacientes que abandonan la atención buscarán atención médica en los próximos 7 días (10,11), y de ellos, entre un 10-15% requerirá hospitalización en su próxima consulta de urgencia (9,12).

Otro problema que también se ve influenciado por el *Overcrowding*, es el *Boarding*, o retención de pacientes en SU. El *Boarding*, refiere a la práctica de mantener a pacientes en la unidad de urgencias luego de que ya se ha tomado la decisión de hospitalizarlos. Se produce debido a la falta de camas o recursos en las áreas designadas a la hospitalización. Desde el punto de vista clínico, se ha evidenciado que la estadía prolongada de pacientes en el área de urgencias puede llevar a retrasos en tratamientos esenciales, con deterioro potencial de la condición de los usuarios y comprometiendo su recuperación. Más aún, se ha demostrado el aumento en la morbilidad, tiempo de estadía de los pacientes, y empeoramiento de la satisfacción del usuario (13–15).

Para la exploración de los desafíos de los Servicios de Urgencia, se realizó una búsqueda en la literatura científica con las siguientes *keywords*: "*emergency department challenges*," "*overcrowding*," "*left without being seen (LWBS)*," "*patient elopement*," "*boarding*," "*emergency department problems*," "*emergency care issues*," "*emergency room congestion*". Las principales bibliotecas y bases de datos utilizadas para la búsqueda fueron Google, Google Scholar, PubMed, Cochrane Library, ScienceDirect, Elsevier y Scielo, considerando la literatura desde el año 1990 a la fecha. Para la información relativa a la realidad chilena se buscó en la Biblioteca digital del Gobierno de Chile, Ministerio de Salud y Departamento de Estadísticas e Información de Salud (DEIS).

1.1.4.- Satisfacción y lealtad del paciente

La satisfacción del usuario es un componente esencial en la evaluación de la calidad de los servicios de salud. Es entendida como la percepción de los usuarios sobre varios aspectos de su relación con el proveedor de salud, incluyendo la atención recibida, la competencia percibida del personal médico, la infraestructura hospitalaria y los tiempos de espera (16). Una experiencia positiva en estos aspectos ha demostrado que afecta positivamente la lealtad del paciente, incentivando su disposición a continuar utilizando los servicios del hospital (16–18).

La lealtad usuaria, por su parte, es un concepto que, si bien se mide mediante la repetición de una elección o la continuidad en la utilización de un servicio, se interpreta como un compromiso sostenido del paciente hacia una institución o proveedor de salud. Dicho compromiso se basa en experiencias pasadas satisfactorias y la confianza en que las futuras interacciones mantendrán o superarán esas experiencias previas (19,20). Desde una perspectiva cognitiva, la lealtad se basa en las creencias y percepciones del paciente sobre la calidad y eficacia del cuidado recibido. Si un paciente cree firmemente que una institución de salud es la mejor opción para sus necesidades, es más probable que mantenga una actitud leal hacia ella. A nivel afectivo, la lealtad está ligada a los sentimientos y emociones del paciente en relación con el proveedor de salud. Estos sentimientos pueden surgir de experiencias directas, como la forma en que un médico interactúa con el paciente, o de aspectos más intangibles, como la reputación general de la institución (20). Desde una perspectiva conductual, la lealtad se manifiesta en acciones concretas, como la elección repetida de un proveedor específico, la recomendación de la institución a amigos y familiares, o la resistencia a cambiar de proveedor incluso cuando se presentan alternativas potencialmente más convenientes o económicas (19–21).

Se han demostrado y modelado factores que afectan la lealtad del paciente hacia una institución de salud, los que se relacionan fuertemente entre ellos, como son la satisfacción usuaria mencionada anteriormente, la calidad del servicio o el profesionalismo percibido por el paciente, y el valor económico percibido de la atención en sí (Figura 5). La calidad del

servicio hace referencia a la excelencia y profesionalismo técnico y funcional del cuidado médico, y la eficiencia de los procedimientos administrativos. El valor percibido es la evaluación del paciente respecto a lo que recibe en comparación con lo que entrega, tanto en términos económicos como emocionales y temporales. Otros determinantes de importancia son la confianza y el compromiso previo del paciente. La confianza en este contexto se refiere a la creencia del paciente de que el hospital actuará en su beneficio, basado en sus experiencias anteriores y en la consistencia y previsibilidad de las acciones del hospital. El compromiso previo, por su parte, se trata de una correspondencia emocional y psicológica del paciente hacia el hospital, que refleja su deseo de mantener una relación a largo plazo y su resistencia a cambiar de institución médica, incluso en la presencia de ofertas potencialmente más atractivas. Es por esto, que la marca del hospital ejerce una influencia significativa en la lealtad. Una marca hospitalaria sólida y bien establecida puede evocar sentimientos de seguridad, confiabilidad y excelencia, lo que contribuye aún más a la lealtad del paciente (19,21).




Figura 5. Determinantes de la lealtad del usuario hacia la institución de salud. Elaboración propia a partir del modelo de determinantes de Lealtad de Zhou (21).

De todos los factores que correlacionan con la lealtad, la satisfacción usuaria es la que ha mostrado un vínculo más directo. Lei (22), compara la satisfacción usuaria con la calidad percibida, demostrando que la primera es la que se asocia de manera más fuerte ($R = 0.48$, $t = 11.07$, $p\text{-value} < 0.05$ y $R = 0.26$ $t = 2.95$ $p\text{-value} < 0.05$) e incluso sería mediadora entre calidad percibida y satisfacción usuaria. Moliner (19), por su parte, analiza la influencia de la satisfacción usuaria, la confianza en el equipo tratante y el compromiso previo con la institución, demostrando que la satisfacción usuaria es el factor más relevante entre los tres ($R = 0.34$ $t = 5.72$, $p\text{-value} < 0.05$, $R = 0.33$ $t = 3.98$, $p\text{-value} < 0.05$, $R = 0.25$ $t = 3.15$, $p\text{-value} < 0.05$ respectivamente). Amin (23), por otro lado, demuestra que la calidad percibida de la atención determina fuertemente la satisfacción usuaria ($R = 0.96$ $p\text{-value} < 0.05$) y que esta a su vez determina la intención de volver a consultar al centro hospitalario ($R = 0.93$ $p\text{-value} < 0.05$). Boshoff (24), por su parte, explora el impacto de diversas dimensiones de la satisfacción del paciente en su lealtad, medida como la disposición a volver a utilizar los servicios del hospital. Los resultados muestran que varios factores relacionados con la experiencia del paciente, como la calidad de los servicios y la atención recibida, tienen un impacto significativo y positivo en la lealtad de los pacientes. El modelo de regresión explica aproximadamente el 68,3% de la variabilidad en la lealtad del paciente ($R^2 = 68,3\%$), indicando que una gran parte de la lealtad puede ser atribuida a los factores de satisfacción medidos en este estudio. La significatividad estadística de estos factores, con valores p menores a 0,01, refuerza el vínculo entre la satisfacción en estas áreas y la probabilidad de que los pacientes elijan regresar al hospital en el futuro.

Cabe destacar que existen otros posibles determinantes de la lealtad de los usuarios no explorados en la literatura, y que se relacionan con las particularidades locales en los que se desarrolla cada sistema de salud. Así, en Chile y, específicamente en Santiago, se han descrito particularidades que incluyen dimensiones que pueden influir significativamente en la elección de la institución por parte de un usuario. En primer lugar, las condiciones económicas y previsionales de los usuarios juegan un papel significativo al incentivar a elegir una institución sobre otra. Por ejemplo, un paciente afiliado al Fondo Nacional de Salud (FONASA) tiene derecho a atenderse de manera gratuita en el sistema público, a diferencia del sistema privado, donde FONASA solo cubre un porcentaje del costo de su atención (25).

Por otro lado, al estar afiliados a ISAPRE, los usuarios son incentivados económicamente a atenderse en determinadas instituciones, debido a convenios específicos entre la ISAPRE y la institución de salud (26). En segundo lugar, el contexto geográfico es un factor crucial, especialmente en localidades donde la oferta de instituciones de salud es más reducida en comparación con Santiago, que cuenta con una mayor densidad de establecimientos de salud, y la oferta existente permite a los usuarios tener más alternativas, incluso (27).

En resumen, los factores que determinan la lealtad del usuario a la institución son múltiples, muchos de ellos inexplorados, probablemente dependiente de la realidad local y con una fuerte influencia entre los mismo. Pese a esto, la satisfacción usuaria ha demostrado ser un factor aglutinante, mediador de diferentes determinantes, y el componente de mayor asociación a la lealtad.

Para explorar los factores que influyen en la lealtad y satisfacción de los usuarios, así como en la elección de un hospital, se realizó una búsqueda en la literatura científica con las siguientes *keywords* en la literatura científica: "*patient loyalty*," "*patient satisfaction*," "*hospital choice*," "*healthcare quality*," "*hospital selection criteria*," "*patient preference*," "*healthcare decision-making*," "*patient experience*," y "*hospital service quality*". Las principales bibliotecas y bases de datos utilizadas para la búsqueda fueron Google, Google Scholar, PubMed, Cochrane Library, ScienceDirect, Elsevier y Scielo.

1.1.5.- Satisfacción y lealtad a la institución a partir de la atención en SU

Según cifras del Ministerio de Salud (MINSAL) (2), casi la mitad de todas las atenciones médicas en Chile se producen en algún SU, constituyendo así la puerta de entrada principal a las instituciones de salud para un alto porcentaje de usuarios. Estas unidades desempeñan un rol clave en moldear la percepción inicial y la confianza que los pacientes desarrollan hacia la institución que los atiende. En este escenario de alta demanda y necesidades inmediatas de cuidado, brindar una atención ágil, adecuada y humana es esencial para construir y consolidar una relación de lealtad y confianza con los pacientes.

La naturaleza dinámica y frecuentemente caótica del entorno de urgencias implica que la experiencia del paciente pueda verse afectada negativamente por factores como tiempos prolongados de espera, *Overcrowding*, abandono prematuro sin atención médica (LWBS) o hospitalización prolongada en urgencias (*Boarding*). La evidencia señala que el *Overcrowding* tiene un impacto significativo en la satisfacción de los usuarios (15,28), mientras que el LWBS disminuye la disposición a consultar nuevamente en el mismo SU (10). Estas situaciones, por lo tanto, no son solo dificultades operativas inmediatas, sino que también repercuten profundamente en la percepción que el paciente tiene sobre la calidad, eficiencia y confiabilidad general de la institución hospitalaria.

1.1.6.- Captura de Datos en SU

La transformación digital en Chile ha marcado un antes y un después en la gestión de la información sanitaria. Esta modernización, ha significado cambios significativos en la forma en que se captura y sistematiza la información de los pacientes a través de los sistemas de registro clínico electrónico (RCE). En el ámbito de la atención de urgencias, esta transformación ha permitido una captura detallada y rigurosa de gran parte de los eventos ocurridos en un SU. Esta se manifiesta en la digitalización del Dato de Atención de Urgencia (DAU), establecido por el Decreto con Fuerza de Ley DFL n°1 MINSAL y la Ley 18.469 (28) junto a la resolución exenta n° 926 del año 1989 que crea la Sección de Orientación Médica y Estadística (SOME) cuyas actividades consisten en establecer los elementos mínimos que debe incluir el DAU. Los elementos mínimos que contempla este decreto, así como los datos registrados habitualmente en los RCE de instituciones de salud públicas en Chile, así como los obtenidos en el HCUCH especificados en la Tabla 1. Gracias a los sistemas de información hospitalarios, se ha logrado ir más allá de estos requisitos mínimos. Con los datos que se incluyen actualmente en el DAU, hoy, los centros hospitalarios, según sus capacidades tecnológicas, pueden obtener desde este documento información clínica y administrativa relevante y en gran volumen, que tiene el potencial de abordar los acuciantes desafíos de los SU. Es en este contexto, donde la aplicación de técnicas de aprendizaje de máquinas y análisis de datos avanzados ofrece una oportunidad inmejorable para avanzar en este camino.

Características	Decreto DAU	DAU en SU con RCE	DAU HCUCH
Identificación	✓	✓	✓
Información Demográfica y Previsional	✓	✓	✓
Modo de Llegada	✓	✓	✓
Categorización	✓	✓	✓
Signos vitales	✓	✓	✓
Hipótesis Diagnóstica	✓	✓	✓
Destino	✓	✓	✓
Médico Responsable	✓	✓	✓
Fecha/Hora Admisión		✓	✓
Fecha/Hora Triage		✓	✓
Fecha/Hora Consulta		✓	✓
Fecha/Hora Alta	✓	✓	✓
Fecha/Hora Hospitalización			✓
Fecha/Hora Alta Hospitalización			✓
Servicio de Destino			✓

Tabla 1. Comparación entre los elementos mínimos del Dato de Atención de Urgencia (DAU) según la ley que lo exige (21), lo que producen los RCE de los hospitales públicos y lo que se elabora a partir del RCE del HCUCH. Elaboración propia.

1.1.7.- Hospital Clínico de la Universidad de Chile (HCUCH)

Continuador de la obra del Hospital San Vicente de Paul, fundado el 1875, el Hospital Clínico de la Universidad de Chile, inaugurado en 1952, ostenta el título de ser el primer hospital universitario del país. Este establecimiento no solo ha sido cuna de innumerables avances médicos y académicos, sino que también ha jugado un papel crucial en la formación de generaciones de profesionales de la salud. Su inauguración marcó un antes y un después en el panorama de la atención sanitaria y la educación médica en Chile, estableciendo un modelo de integración entre la enseñanza universitaria y la práctica clínica que ha sido emulado a lo largo de los años (29).

Sin embargo, desde el año 1994, el Hospital Clínico de la Universidad de Chile experimentó un cambio significativo en su estructura administrativa, distanciándose de la red asistencial pública. Aunque sigue siendo propiedad del Estado de Chile, gestionado por la Universidad de Chile, su funcionamiento se asemeja al de un hospital privado. Esto implica que atiende a pacientes de aseguradoras privadas tanto como de Fonasa, a través de la modalidad de libre elección. Este modelo único combina la excelencia académica con una gestión orientada a satisfacer las necesidades de una amplia gama de pacientes, lo que plantea desafíos únicos en cuanto a la prestación de servicios y la fidelización de los usuarios.

En este esquema de operaciones, el hospital ha adoptado desde hace más de 12 años el uso de un sistema de RCE que ha fortalecido la manera en que se recopila, almacena y gestiona la información clínica de los pacientes. La implementación de este sistema ha permitido mantener un registro clínico de alta calidad, totalmente electrónico, disponible y acorde a los estándares de seguridad vigentes.

Este sistema de registro es fundamental para este proyecto por varias razones. En primer lugar, asegura la integridad y la confiabilidad de la información que se utilizará para analizar los patrones de lealtad de los usuarios. Además, facilita la exploración detallada y el procesamiento de grandes volúmenes de datos clínicos y administrativos, permitiendo identificar factores clave que influyen en la percepción y satisfacción del paciente. Por lo tanto, la calidad y profundidad de los datos disponibles son esenciales para desarrollar un análisis predictivo eficaz que pueda servir como base para las estrategias destinadas a mejorar la experiencia del paciente y, en consecuencia, su lealtad hacia el hospital.

La unidad de urgencias del hospital, que recibe aproximadamente 25,000 pacientes al año, no es ajena a los retos que enfrentan los servicios de urgencia a nivel mundial, tales como el *Overcrowding*, el *Boarding* y un índice de LWBS cercano al 10%. Estos desafíos resaltan la importancia de adoptar estrategias innovadoras para la gestión hospitalaria, particularmente en un entorno competitivo donde la lealtad del paciente hacia la institución se vuelve crucial.

En este contexto, el Hospital Clínico de la Universidad de Chile, respaldado por la prestigiosa marca de la Universidad, se presenta como el escenario ideal para implementar y evaluar proyectos que busquen mejorar la experiencia del paciente, optimizar los flujos de trabajo y, en última instancia, fomentar una mayor lealtad hacia el hospital. Este enfoque no solo es fundamental para asegurar la sostenibilidad y el crecimiento del hospital, sino que también se alinea con su misión de proporcionar una atención de calidad y accesible, reflejando los valores de excelencia e innovación que han caracterizado a la Universidad de Chile desde su fundación.



Figura 6. Frontis del Hospital Clínico de la Universidad de Chile (29). Fuente: Página web institucional.

1.2.- Aprendizaje de máquinas

El aprendizaje de máquinas, aprendizaje automático o *Machine Learning* (ML), es una rama de la inteligencia artificial que permite a las computadoras aprender y mejorar su performance a partir de los datos, sin ser programadas explícitamente para cada tarea. Este enfoque se basa en el desarrollo de algoritmos que pueden procesar grandes volúmenes de datos, identificar patrones y hacer predicciones o tomar decisiones basándose en esa información. A través de este proceso, las máquinas pueden optimizar su rendimiento, adaptándose y respondiendo a nuevas situaciones de manera similar a como lo haría un humano, pero a una escala y velocidad mucho mayores. La capacidad de aprender de los datos hace que el ML sea tenga un enorme potencial en la medicina salud (30,31).

La construcción de modelos predictivos sobre usuarios o clientes proporciona ventajas significativas respecto a la búsqueda de simples correlaciones que identifican elementos generales de algún proceso. Esto se debe a que estos algoritmos proporcionan herramientas para la construcción e implementación de sistemas de soporte a todo tipo de decisiones. Estos sistemas, basados en dichos algoritmos, permiten tomar medidas ajustadas al usuario y a menor costo, práctica estándar actualmente en empresas tecnológicas que disponen de grandes volúmenes de datos. Al utilizar este tipo de modelos, las organizaciones pueden anticipar comportamientos futuros y personalizar sus estrategias para mejorar la experiencia y satisfacción del usuario, optimizando los recursos y mejorando la eficiencia en la toma de decisiones (30).

Para que un proyecto de ML sea exitoso, debe regirse por un flujo de trabajo establecido y estructurado, que comienza con una clara definición y comprensión del problema a abordar. Posteriormente, se elabora o se obtiene un base de datos, donde se recolectan y compilan los datos necesarios para el análisis. Luego se realiza la selección de la muestra, aplicando criterios de inclusión y exclusión para garantizar que los datos sean representativos y relevantes. Una vez definida la muestra, se procede con una limpieza inicial de los datos, para tratar problemas como valores faltantes, duplicados y anomalías evidentes, y así llevar a cabo el Análisis Exploratorio de Datos (EDA), en el que se examina la estructura, distribución y relaciones entre variables, proporcionando *insights* valiosos para el preprocesamiento. El preprocesamiento de los datos es el siguiente paso, en el cual se transforman y normalizan las variables para facilitar y optimizar su análisis y modelado. Después de esta preparación, se selecciona y construye el modelo de aprendizaje automático más adecuado para los datos y el problema específico. Este modelo se evalúa y ajusta para optimizar su rendimiento y finalmente se procede a la interpretación de los resultados, en la que se extraen conclusiones y se toman decisiones basadas en los hallazgos obtenidos. Este proceso integral asegura un enfoque metódico y efectivo en la solución de problemas mediante el aprendizaje automático (30,31). A continuación, las etapas y definiciones más relevantes.

1.2.1.- Preprocesamiento de Datos

El preprocesamiento de datos en el contexto del aprendizaje automático es una fase que determina el éxito del modelo, implicando la preparación y transformación de los datos crudos para hacerlos aptos para el modelado. Este proceso incluye una serie de pasos destinados a convertir los datos en un formato que los modelos de aprendizaje automático puedan interpretar eficientemente. Estas técnicas no solo mejoran la calidad y la eficiencia del análisis, sino que también son esenciales para aumentar la precisión y el rendimiento de los modelos de aprendizaje automático. El preprocesamiento efectivo asegura que los datos se presenten de manera que maximice el potencial de extracción de patrones y conocimientos útiles, siendo un paso indispensable en cualquier proyecto de ciencia de datos o aprendizaje automático. El preprocesamiento incluye las siguientes técnicas y herramientas (30,31):

Imputación de Valores Faltantes. Los valores faltantes son comunes en muchos conjuntos de datos y deben ser tratados adecuadamente. La imputación es el proceso de reemplazar estos valores faltantes con sustitutos, que pueden ser la media, mediana, moda o incluso valores estimados mediante modelos predictivos. La elección de la técnica de imputación depende de la naturaleza de los datos, el patrón de los valores faltantes y el modelo que se decida utilizar (32).

Codificación de Variables Categóricas. Muchos algoritmos de aprendizaje automático requieren que todas las entradas sean numéricas. Las variables categóricas, como el género o el país, deben ser transformadas en valores numéricos. Esto se puede hacer mediante diferentes técnicas dependiendo de la naturaleza de la variable, las técnicas más comunes son la codificación *One-Hot*, *Label Encoding* o la utilización de *embeddings* en casos más complejos (30).

Normalización. La normalización es un paso crucial en el preprocesamiento de datos, especialmente cuando las variables predictoras tienen rangos de valores muy diferentes. Este proceso implica ajustar los valores de las características a una escala común, generalmente entre 0 y 1 o -1 y 1, lo que permite que el modelo trate todas las variables de manera

equitativa. La normalización es particularmente importante en algoritmos que son sensibles a la escala de los datos, como aquellos basados en distancias (por ejemplo, K-NN) o en gradientes (como las redes neuronales), ya que evita que las variables con mayor amplitud dominen el proceso de aprendizaje (33).

Tratamiento de *Outliers*. El tratamiento de *outliers* implica identificar y manejar las observaciones que se desvían significativamente del patrón general de los datos. Los *outliers* pueden ser resultado de errores de medición o variaciones naturales, y su tratamiento es esencial porque pueden sesgar los resultados del análisis y afectar la precisión del modelo. Previo al tratamiento de los *outliers* es fundamental comprender el problema, el método de registro de datos, y análisis en el EDA para comprender su origen. Las técnicas para manejar *outliers* incluyen su modificación (por ejemplo, imputación), su eliminación, entre otros. Una de las maneras de manejar *outliers* es a través de la *winsorización*, que es una técnica que consiste en reemplazar los valores extremos por un percentil determinado del mismo conjunto (34).

Eliminación de variables no informativas. Este paso involucra identificar y remover las variables que no contribuyen información significativa al modelo. Las variables no informativas son aquellas que tienen poca o ninguna variabilidad, o que no están correlacionadas con la variable objetivo. Eliminar estas variables reduce la complejidad del modelo, mejora la eficiencia computacional y previene el sobreajuste, asegurando que el modelo se centre solo en las características relevantes que realmente influyen en la predicción (35).

Generación de Características (*Feature Engineering*). En ocasiones una variable por sí sola no entrega mucha información en el modelo, por lo que la creación de nuevas características a partir de las ya existentes puede mejorar significativamente la capacidad predictiva del modelo. Esto puede incluir la transformación de variables (como logaritmos o raíces cuadradas), la creación de interacciones entre variables, o la extracción de información a partir de variables complejas como fechas o textos (36).

1.2.2.- Selección y Entrenamiento del Modelo

La selección y entrenamiento del modelo son etapas decisivas en cualquier proyecto de aprendizaje automático. Un modelo en este contexto es un algoritmo que intenta predecir o clasificar datos basándose en patrones aprendidos de un conjunto de datos de entrenamiento.

El proceso comienza con la selección de un modelo apropiado, basándose en la naturaleza del problema y datos disponibles. Luego, sigue el entrenamiento, en el que el modelo aprende de los datos proporcionados, ajustando sus parámetros internos para poder hacer predicciones precisas o clasificaciones sobre nuevos datos. Este proceso requiere una consideración cuidadosa del tipo de modelo a utilizar, su complejidad, y cómo se ajusta a los datos (30,37).

Dentro del aprendizaje automático, existen principalmente dos tipos de aprendizaje: el supervisado y el no supervisado. El aprendizaje supervisado implica modelos que se entrenan usando un conjunto de datos etiquetados, en los que cada entrada de datos tiene una salida correspondiente o etiqueta. El objetivo es aprender un mapeo de entradas a salidas que pueda predecir las etiquetas de nuevos datos. Por otro lado, el aprendizaje no supervisado utiliza datos que no están etiquetados, por lo que se deben descubrir patrones ocultos o estructuras intrínsecas en los datos (30).

Los modelos de aprendizaje automático supervisado, a su vez, pueden categorizarse en dos tipos basados en el tipo de variable que predicen: regresión y clasificación. Los modelos de regresión predicen una variable continua. Por otro lado, los modelos de clasificación predicen categorías discretas, asignando entradas de datos a clases o etiquetas específicas. Cada tipo de modelo tiene su propio conjunto de algoritmos y técnicas. La elección entre regresión y clasificación depende intrínsecamente del tipo de pregunta o problema que se esté intentando responder o resolver. Algunos de los modelos de aprendizaje automático más usados son:

Random Forest (RF). Es un algoritmo de aprendizaje supervisado que utiliza el método de ensamble conocido como *Bagging*. Este algoritmo construye múltiples árboles de decisión durante el entrenamiento y realiza la predicción mediante la combinación (por ejemplo,

votación para clasificación o promedio para regresión) de los resultados de todos los árboles. Esto mejora significativamente la precisión predictiva y reduce el sobreajuste, ya que la combinación de diversos modelos reduce el riesgo de errores asociados a un solo árbol de decisión. *Random Forest* es efectivo para clasificación y regresión y es robusto frente a datos atípicos y no balanceados (38).

XGBoost y LightGBM son algoritmos de aprendizaje supervisado basados en *gradient boosting*, una técnica de ensamble que construye árboles de decisión de forma secuencial, donde cada nuevo árbol corrige los errores del anterior. XGBoost (Extreme Gradient Boosting) es conocido por su alta eficiencia, capacidad de regularización y robustez ante el sobreajuste, siendo ampliamente utilizado en contextos de clasificación y regresión con grandes volúmenes de datos. Por su parte, LightGBM (Light Gradient Boosting Machine) es una implementación más reciente y optimizada que utiliza un enfoque basado en histogramas y crecimiento por hojas (*leaf-wise*), lo que permite un entrenamiento más rápido y menor uso de memoria, aunque con mayor riesgo de sobreajuste. Ambos modelos ofrecen alto rendimiento predictivo y han sido validados en contextos clínicos complejos, destacando por su flexibilidad y capacidad para manejar datos no estructurados. (39).

Redes Neuronales (*Neural Network* o NN). Son un conjunto de algoritmos inspirados en la estructura y función del cerebro humano, diseñados para reconocer patrones. Están compuestas por nodos o “neuronas” organizados en capas, donde cada nodo está conectado con varios nodos en la capa siguiente. Estas conexiones representan pesos sinápticos que se ajustan durante el proceso de entrenamiento. Las redes neuronales son capaces de modelar relaciones complejas y no lineales entre las características y pueden ser utilizadas tanto en clasificación como en regresión (37).

Regresión Logística (RegLog). La Regresión Logística es un algoritmo utilizado ampliamente en aprendizaje automático para predecir la probabilidad de una variable dependiente categórica. En el caso de una respuesta binaria, como 'sí' o 'no', la Regresión Logística modela la probabilidad de que una observación pertenezca a una de las categorías. Utiliza una función logística para modelar una variable dependiente binaria, lo que permite

la estimación de probabilidades y la clasificación de las observaciones. Es particularmente útil debido a su simplicidad, eficiencia y la facilidad con la que se pueden interpretar los resultados. Además, permite estimar el impacto de una o más variables independientes sobre la probabilidad de ocurrencia de un evento (30).

Elastic Net. Es una extensión moderna de la regresión logística que incorpora un mecanismo de penalización sobre los coeficientes del modelo, con el fin de evitar el sobreajuste y mejorar la capacidad de generalización. Esta técnica es especialmente útil cuando se trabaja con un gran número de variables predictoras o con alta correlación entre ellas, ya que permite seleccionar automáticamente las variables más relevantes. *Elastic Net* ofrece una solución robusta y capacidad predictiva con interpretabilidad, lo que la hace adecuada para aplicaciones clínicas donde se busca un equilibrio entre precisión y simplicidad (40).




Figura 7. Esquema jerárquico del aprendizaje de máquinas. Distingue si los datos incluyen una variable a predecir. Si la incluye, es aprendizaje supervisado y se divide según el tipo de variable a predecir: si es continua, se usan algoritmos de regresión; si es categórica, algoritmos de clasificación (41). Esta estructura permite seleccionar el tipo de modelo según el problema. Elaboración propia.

1.2.3.- Evaluación del desempeño de los algoritmos implementados.

La evaluación de desempeño del modelo en aprendizaje automático mide la efectividad del modelo en realizar predicciones precisas. Para los modelos de clasificación, se utiliza la matriz de confusión, que representa visual las observaciones, comparando los valores reales con los predichos, ayudando a identificar no solo las predicciones correctas, sino también el tipo de errores cometidos (30).

		Clase Real	
		Positivo	Negativo
Clase Predicha	Positivo	Verdadero Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadero Negativo (VN)

Tabla 2. Matriz de Confusión (30). Elaboración propia

Respecto a las métricas de evaluación algunas de estas son Exactitud, Precisión, Sensibilidad, Especificidad, F1 Score, ROC y AUC. Estas métricas proporcionan una evaluación cuantitativa del rendimiento del modelo. La exactitud mide la proporción de predicciones correctas entre todas las predicciones realizadas. La precisión evalúa cuántas de las clasificaciones positivas del modelo son realmente positivas. La sensibilidad mide la capacidad del modelo para identificar correctamente las observaciones positivas. La especificidad evalúa cómo el modelo identifica correctamente las observaciones negativas. El *F1 Score*, por su parte, es una medida armónica de la precisión y la sensibilidad, útil cuando se busca un equilibrio entre estas dos métricas o cuando las clases a predecir se encuentran desbalanceadas (30).

$$\text{Exactitud (Accuracy)} = \frac{VP + VN}{VP + VN + FP + FN} \qquad \text{Precisión} = \frac{VP}{VP + FP}$$

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \qquad \text{Especificidad} = \frac{VN}{VN + FP}$$

$$\text{F1 Score} = 2 * \frac{\text{Precisión} * \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

Figura 8. Métricas para la evaluación de desempeño de clasificadores. Elaboración propia a partir de Geron et al (30).

La curva ROC (Receiver Operating Characteristic) (Figura 9) es una herramienta gráfica ampliamente utilizada para evaluar el desempeño de clasificadores binarios, representando el compromiso entre sensibilidad y especificidad al variar el umbral de decisión del modelo. En el ámbito de la salud, es fundamental comprender claramente el propósito específico del modelo predictivo, ya que esto determina la elección de la métrica más adecuada. Por ejemplo, en tamizajes poblacionales, es prioritario evitar falsos negativos, favoreciendo así modelos con alta sensibilidad. En cambio, cuando los falsos positivos y negativos tienen impactos similares, métricas como el F1 score resultan más relevantes, al ponderar ambos tipos de errores en un único umbral. La principal ventaja del ROC AUC es precisamente que analiza simultáneamente sensibilidad y especificidad a través de todos los umbrales posibles, brindando una evaluación integral del desempeño del clasificador. Esto facilita una elección estratégica posterior, según la capacidad predictiva del modelo y los objetivos clínicos específicos, además de mantener su utilidad incluso en contextos con clases desbalanceadas, al basarse en tasas relativas y no en conteos absolutos (41).




Figura 9. Representación de curvas ROC con diferentes valores de AUC (área bajo la curva). Un AUC cercano a 0,5 indica un modelo sin capacidad discriminativa, equivalente al azar, mientras que valores sobre 0,75 se consideran aceptables y sobre 0,9 excelentes. Cada punto en la curva representa un umbral de decisión distinto, donde se calcula la sensibilidad y especificidad resultante, permitiendo evaluar el desempeño del modelo en todos los escenarios posibles. Esta visualización facilita elegir el umbral óptimo según las prioridades clínicas (30). Elaboración propia.

1.2.4.- Aprendizaje de máquinas para el estudio de la lealtad

Invertir en mejorar la satisfacción del cliente y en fomentar su lealtad hacia una institución es una estrategia bastante común en el ámbito empresarial. Según una encuesta realizada por el MIT y Google a empresas de alto impacto, más del 50% de las encuestadas implementan estrategias de aprendizaje automático para entender mejor a sus clientes y, consecuentemente, mejorar la toma de decisiones (42).

Para la realización de cualquier proyecto de este tipo, es necesario llevar a cabo una búsqueda exhaustiva de estudios o trabajos similares para conocer el estado del arte, sin embargo, en el sector salud, no se ha documentado proyectos de esta naturaleza en revistas destacadas o en las más grandes plataformas y comunidades de científicos de datos como Kaggle (43). Esta falta de precedentes motiva a profundizar en el estudio de la lealtad en el sector sanitario y, a la vez, obliga a buscar en otras industrias proyectos análogos, a pesar de que esto pueda introducir algunos sesgos en el proceso, debido a las diferencias de contexto y de negocio.

La revisión de estos estudios otorgó valiosas lecciones para abordar la lealtad hacia una institución de salud. Aunque las métricas de lealtad varían significativamente de una industria a otra, reflejando las particularidades de cada sector, esta diversidad en la definición y medición de la lealtad subraya una lección fundamental: la importancia de desarrollar un enfoque adaptado y específico que responda a las características y necesidades únicas del entorno de la salud. Por ejemplo, mientras que en el sector financiero se puede cuantificar la lealtad a través del número de transacciones, en un contexto de servicios de salud, la lealtad podría medirse mediante la frecuencia de visitas o la elección continua de la institución para recibir cuidados, en este sentido la lealtad podría ser una variable continua o una variable discreta, con la respectivas implicancias en el desarrollo de los modelos de aprendizaje (Tabla 3).

Estudio	Variable por Predecir	Industria	Modelo	Métrica	Comentarios
LightGBM: an Effective Decision Tree Gradient Boosting Method to Predict Customer Loyalty in the Finance Industry.	Lealtad: Variable continua mediante un Score calculado para la empresa según compras en un plazo de dos meses.	Financiera	Regresión: LightGBM, XGBoost	RMSE: 3.6 4.5	La lealtad es hacia el uso de una tarjeta bancaria, por lo que el periodo para el cálculo de lealtad es mínimo.
The Prediction of Hotel Customer Loyalty using Machine Learning Technique	Lealtad: Variable binaria. Define lealtad según si el cliente ya había hecho alguna reserva.	Turismo: Hotelería	Clasificación RF	Accuracy: 0.989	La lealtad hacia el hotel es según se ha alojado previamente, no pone temporal límite al cálculo de la lealtad.
Comparative Analysis of Accuracy and Prediction of Customer Loyalty in the Telecom Industry using Novel Diverse Algorithm	Lealtad: Variable binaria. Define lealtad según si el cliente persiste afiliado a la compañía	Telecom.	Clasificación RegLog, KNN, SVM	Accuracy: 0.8 0.79 0.76	El algoritmo predice dos clases, uno clientes ya desafiliados y otros aún leales a la compañía.
Customer churn prediction system: a machine learning approach	Lealtad: Variable binaria. Define lealtad según si el cliente persiste afiliado a la compañía	Telecom.	Clasificación RegLog, RF, SVM, AdaBoost, XGBoost	AUC: 0.82 0.82 0.79 0.84 0.84	El algoritmo predice dos clases, uno clientes ya desafiliados y otros aún leales a la compañía.
Lifelog Data-Based Prediction Model of Digital Health Care App Customer Churn: Retrospective	Lealtad: Variable binaria. Define lealtad según los usuarios de la app persisten suscritos a ella.	Salud	Clasificación NN	F1 Score 0.77	Toma usuarios suscritos a una aplicación móvil de salud buscando predecir quienes al final del periodo permanecieron suscritos.

Tabla 3. Modelos de aprendizaje de máquinas para la predicción de lealtad en diferentes industrias. Se destaca que el tipo de industria determina la metodología a través de la cual se operacionaliza el concepto de lealtad. Elaboración propia.

De estos estudios analizados, se desprende que la elección de algoritmos de aprendizaje automático debe estar guiada tanto por la naturaleza de los datos disponibles como por el contexto específico de su aplicación. Por ejemplo, para aquellos proyectos que identificaban la lealtad como una variable discreta binaria, se evidenció que el uso de técnicas de ensamble

y *Boosting*, podrían ofrecer enfoques robustos para mejorar la precisión de los modelos de predicción de lealtad (44).

Por otro lado, es crucial decidir la forma a través de qué métricas será medido el desempeño de los modelos, como Accuracy, F1 Score o el área bajo la curva ROC, dependiendo de cómo se defina la lealtad en el estudio y qué es lo que se desee priorizar (44–47). Esta evaluación es vital para asegurar que el modelo no solo sea preciso, sino también relevante para las decisiones prácticas, comparación con otros proyectos, y el desarrollo posterior de intervenciones diseñadas para mejorar la lealtad del paciente. En el caso de estos estudios en particular, se decidieron en términos generales por Accuracy y área bajo la curva ROC, ambas métricas globales del rendimiento, siendo el área bajo la curva ROC menos sensible al desbalance de clases.

Pese a tener esta aproximación de lealtad en otros sectores, al no haber identificado proyectos en la literatura que predigan lealtad del paciente hacia instituciones de salud nos encontramos con una limitación al momento de diseñar y evaluar nuestro modelo. Sin embargo, al considerar que la satisfacción del paciente se identifica como el factor más importante para determinar su lealtad, es razonable utilizar proyectos de ML enfocados en la predicción de la satisfacción del paciente como referencia válida al momento de establecer comparaciones para el desarrollo de modelos que apunten a lealtad. Si la satisfacción del usuario ha sido previamente predicha con una eficacia aceptable, se puede plantear la hipótesis de que la lealtad del paciente también podría predecirse con una eficacia comparable, bajo la premisa de que la satisfacción actúa como un precursor o indicador clave de la lealtad. A continuación, se describen algunos proyectos que tienen como objetivo la predicción de la satisfacción del paciente Tabla (4).

Los estudios mencionados sobre satisfacción usuaria en contexto hospitalario, aunque no enfocados directamente en la lealtad, ofrecen una base sólida para explorar qué variables clínicas y administrativas pueden influir tanto en la satisfacción usuaria como indirectamente en la lealtad del paciente.

Estudio	Variable por Predecir	Industria	Modelo	Métrica	Comentarios
Exploring drivers of patient satisfaction using a random forest algorithm	Satisfacción usuaria	Salud	Clasificación RF	Accuracy 0.93	El estudio predice satisfacción usuaria a través de variables relativas a usuario y prestador.
An approach to predicting patient experience through machine learning and social	Satisfacción usuaria a través de predecir respuestas a la encuesta de satisfacción usuaria.	Salud	Clasificación RF	AUC 0.876 0.819 0.819	El estudio predice satisfacción indirectamente, prediciendo las respuestas
Gaining insights into patient satisfaction through interpretable machine learning	Satisfacción usuaria	Salud	Clasificación NN Lasso XGBoost	AUC 0.869 0.863 0.865	El estudio predice la satisfacción usuaria a través de diferentes algoritmos, utilizando como predictores variables relativas al usuario y a la atención.
Application of Data Mining Techniques to Determine Patient Satisfaction	Satisfacción usuaria	Salud	Clasificación Naïve Bayes Arboles de decisión AdaBoost	Accuracy 0.87 0.83 0.87	El estudio predice satisfacción usuaria a través predictores relativos al usuario, al hospital y a características de su atención de salud.
Exploring drivers of patient satisfaction using a random forest algorithm	Satisfacción usuaria	Salud	Clasificación RF	Accuracy 0.93	El estudio predice satisfacción usuaria a través de variables relativas a usuario y prestador.

Tabla 4. Modelos de aprendizaje de máquinas para la predicción de satisfacción usuaria hospitalaria. Se destaca el uso de algoritmos de clasificación y el uso de predictores relativos a usuario, prestador y experiencia durante la hospitalización. Elaboración propia.

En estos estudios se observa la integración de una amplia gama de variables en los modelos predictivos, incluyendo desde información demográfica hasta detalles específicos de la atención médica recibida, resaltando la necesidad de un enfoque holístico en la recopilación

de datos. Esto muestra cómo la combinación de datos clínicos, administrativos y de percepciones de los pacientes puede ofrecer una vista completa sobre los factores que influyen en la lealtad. Se destaca en la evidencia disponible, la relevancia de variables directamente relacionadas con la experiencia del paciente, tales como el trato, la entrega de información de forma comprensible, y una escucha atenta. Estos aspectos, estrechamente vinculados a la satisfacción, subrayan tanto la importancia de incorporarlos de alguna manera en el desarrollo de estos modelos, como de enfocar esfuerzos en mejorar la calidad de la atención como medio para fomentar la lealtad de los pacientes (48–51).

Los proyectos han demostrado ser efectivos en predecir la satisfacción basada en diferentes variables que pueden adaptarse para predecir lealtad, considerando sus variables clínicas y administrativas específicas, por lo que es esperable que exista semejanza al predecir lealtad. Pese a lo anterior, es importante destacar que algunos de estos estudios recopilan información sobre la satisfacción del paciente a través encuestas sobre sus experiencias y percepciones. Dichas encuestas incluyen preguntas que, como se demuestra, son fuertemente predictoras de la satisfacción y otorgan una significativa capacidad predictiva al modelo. Sin embargo, este enfoque podría no ser aplicable en situaciones donde este tipo de información no esté disponible. Las respuestas de las encuestas pueden ser un gran predictor de la disposición del paciente a mantener una relación a largo plazo con la institución, por lo que la ausencia de este tipo de datos podría resultar en una disminución de la capacidad predictiva de los modelos en comparación con aquellos proyectos que sí disponen de dicha información.

En suma, los estudios sobre satisfacción usuaria en el contexto hospitalario proporcionan una comparativa razonable para entender como variables clínicas y administrativas afectan la lealtad del paciente. Variables relacionadas con la experiencia del paciente, han demostrado influencia en la satisfacción y, por ende, la lealtad. Aunque es información valiosa, es importante considerar que la predicción de la lealtad puede verse afectada por la disponibilidad de esos datos específicos, los cuales poseen un gran poder predictivo, pero solo se encuentran disponibles a través de encuestas de satisfacción, por lo que se presenta el desafío de descubrir, dependiendo del contexto específico que se estudie, qué variables medibles retrospectivamente podrían afectar de manera similar a estas.

1.3.- Problema & Solución propuesta

El cultivo de lealtad del usuario hacia una institución de salud es de gran importancia, tanto para el bienestar del paciente como para la institución de salud. Los SU hospitalarios, dado su gran volumen de atención, variabilidad de problemas clínicos y de gestión, así como su carácter de “primer contacto” con el centro asistencial en un gran porcentaje de los casos, lo convierte en un escenario idóneo, tanto para estudiarla como para fomentarla.

Problemas como tiempos de espera prolongados, *Overcrowding*, LWBS, o *Boarding*, entre otros, influyen negativamente en la percepción del paciente, erosionan la confianza y satisfacción del usuario, con implicancias negativas para la lealtad, por lo que el desarrollo de herramientas para manejar estas complejidades se transforma en un imperativo si se desea cultivar la lealtad.

Este proyecto propone utilizar algoritmos de aprendizaje de máquinas para predecir la lealtad del usuario hacia la institución luego de su atención de urgencia, expresado como consultas posteriores a la atención, en cualquiera de las líneas asistenciales de la institución. Para esto se utilizará la información obtenida de la atención de urgencia, capturada en la confección del Dato de Atención de Urgencia (DAU) y almacenada en ficha clínica electrónica. Se espera que a partir de estos datos se pueda obtener información tanto de características de pacientes como estimadores de los obstáculos frecuentes de los SU ya mencionados, a fin de ser utilizados como variables predictoras.

De esta manera, se pretende utilizar un recurso ampliamente disponible como el DAU para entregar un insumo valioso a la hora de implementar medidas orientadas al cultivo de la lealtad hacia la institución.

2.- Hipótesis

Entendiendo la lealtad como un problema de predicción de dos clases, que correlaciona fuertemente con la satisfacción usuaria, se plantea la siguiente hipótesis:

“La información clínica registrada en el sistema de información hospitalaria tras recibir una atención de urgencia predice la lealtad de los usuarios hacia la institución de salud. Se espera una predicción con un área bajo la curva ROC mayor al 82%”

3.- Objetivo General

Predecir la lealtad de los usuarios hacia la institución a partir de la información clínica registrada en el sistema de información hospitalaria tras recibir una atención de urgencia.

4.- Objetivos específicos

1. Generar un conjunto de datos limpio, coherente y preprocesado a partir de la información almacenada en el sistema de información hospitalaria del HCUCH.
2. Implementar diferentes algoritmos de Aprendizaje de Máquinas de clasificación para la predicción de lealtad a partir de los datos obtenidos.
3. Comparar el desempeño de los algoritmos implementados.
4. Interpretar los resultados del análisis para identificar las variables predictoras más importantes y proporcionar sugerencias basadas en estos hallazgos para promover la lealtad al establecimiento.

5.- Materiales y Método

5.1.- Generar un conjunto de datos limpio, coherente y preprocesado a partir de la información almacenada en el sistema de información hospitalaria del HCUCH.

5.1.1.- Obtención de datos y Criterios de exclusión

Este proyecto se llevó a cabo con el apoyo del Hospital Clínico de la Universidad de Chile (HCUCH). Se analizarán los datos de pacientes adultos que ingresaron al SU del HCUCH durante el periodo de 2015 a 2019, través de la información almacenada en la ficha clínica electrónica que ha estado en uso durante estos años en el hospital. El uso de esta herramienta ha permitido la recolección consistente de datos relevantes, los cuales se han mantenido actualizados, completos y de buena calidad, para el uso en proyectos de investigación.

El HCUCH es idóneo para este estudio debido a su modelo de atención único que opera con un enfoque similar al de un hospital privado, a pesar de ser propiedad del Estado y gestionado por la Universidad de Chile. Este modelo requiere un enfoque particular en la lealtad del paciente, ya que la captación y retención de pacientes es crucial para su sostenibilidad. Por otro lado, la utilización de la ficha clínica electrónica TiCares por más de una década en el HCUCH asegura la integridad y la confiabilidad de los datos, que son fundamentales para analizar la lealtad de los pacientes y desarrollar intervenciones efectivas para mejorar su experiencia y fidelización.

Este proyecto se centrará exclusivamente en los pacientes que fueron atendidos en el servicio de urgencias adulto, excluyendo aquellos que fueron tratados en la urgencia obstétrica y los pacientes pediátricos, quienes por protocolo no deben ser atendidos en el SU. Este criterio de exclusión garantiza que los datos analizados sean relevantes y específicos para nuestro objetivo de investigación.

Una vez obtenidos, los datos son anonimizados de acuerdo con el estándar HIPAA para la protección de la información de los pacientes, lo que impide su trazabilidad (52).

La Dirección del Hospital Clínico de la Universidad de Chile junto a su Comité Ético Científico de Investigación autorizan la revisión de Fichas Clínicas de pacientes que ingresaron al servicio de urgencias durante 2015 y 2020 según consta en el Certificado N° 69 del 23 de agosto de 2023. Esta autorización es un paso fundamental que subraya el compromiso del estudio con los más altos estándares éticos y legales, que garantiza que el manejo de la información clínica se realice de manera responsable y con el respeto debido a la privacidad y los derechos de los pacientes. La aprobación del comité no solo valida la importancia y relevancia del proyecto, sino que también asegura que todas las actividades de investigación se desarrollen dentro de un marco ético riguroso.

5.1.2.- Variables a extraer

Durante la etapa de recolección de datos, se contempló la extracción de variables relevantes desde el sistema de registro del SU, abarcando tres grandes categorías: información demográfica, antecedentes clínicos y variables administrativas con hitos temporales asociados al flujo asistencial. Esta clasificación busca capturar de manera integral las características del paciente y su proceso de atención, facilitando el análisis de su posible relación con la lealtad institucional.

5.1.3.- Variable por predecir: Lealtad

La variable por predecir, es decir, la lealtad del usuario a la institución se obtiene mediante el registro de una posterior utilización de los servicios hospitalarios por parte de los pacientes, sin embargo, la determinación del periodo de tiempo necesario entre la atención observada y la próxima para que el cliente sea considerado leal presentó dificultades en su consideración, dado que no existe un estándar establecido en la literatura. Por ejemplo, en el sector de las suscripciones a aplicaciones o servicios de *streaming*, la lealtad se evalúa mes a mes, midiendo la continuidad de la suscripción hasta su cancelación (45). En contraste, en el turismo, donde la frecuencia de uso tiende a ser más esporádica, la lealtad puede manifestarse

a lo largo de años, manteniendo un compromiso continuo con el servicio o destino incluso después de períodos prolongados sin consumo (47).

En este contexto, se decidió en este proyecto no establecer un plazo límite en el tiempo para determinar la lealtad de un paciente hacia la institución. Esto porque se consideró que el paciente puede mantener lealtad a la institución y no presentar ningún tipo de consulta en varios meses incluso años, sino que debido únicamente a la ausencia de motivos que lo lleven a consultar en el tiempo de estudio, sesgando los resultados a pacientes que tienen mayor probabilidad de consultar (adultos mayores). Además, se tomó la decisión de no limitar el plazo que considera el impacto de la pandemia de COVID-19 y la consecuente reducción en las consultas médicas durante esos años. Aunque este método puede presentar ciertas limitaciones, se decide por el hecho de ser el enfoque más sensible para medir la lealtad bajo las circunstancias dadas.




Figura 11. La lealtad será operacionalizada a partir de la futura utilización de los servicios de la institución. Luego de la atención en SU el paciente será leal si se atendió en las siguientes líneas asistenciales. No se consideran otras líneas asistenciales (Imagenología o Laboratorio). No se define un límite de tiempo para la utilización de los servicios. La hospitalización no debe ser parte del proceso de urgencia actual. Fuente: Elaboración propia.

5.1.4.- Análisis exploratorio y Preprocesamiento

En primer lugar, se realiza un análisis general de la muestra obtenida. Este paso preliminar incluye examinar la distribución, centralidad y dispersión de las variables, en busca de patrones, irregularidades o cualquier aspecto que requiera atención especial antes de proceder con análisis más detallados la identificación de cualquier anomalía en la base de datos, datos

faltantes, erróneos, *outliers* y la evaluación del tamaño de la muestra. Estos elementos son cruciales para garantizar la validez y fiabilidad de nuestros hallazgos.

Para investigar la relación entre las variables y la lealtad, se emplearán diversos análisis estadísticos. Estos análisis incluirán correlaciones de Pearson y Spearman, análisis de varianza (ANOVA) y pruebas de chi-cuadrado. Sin embargo, para la adecuada exploración de los datos es fundamental avanzar en el preprocesamiento de las variables,

En la etapa de preprocesamiento se realiza una serie de acciones para preparar los datos para la etapa siguiente. Se comienza con el manejo de valores faltantes, lo que puede implicar eliminar atenciones, variables o aplicando métodos estadísticos para sustituir los datos ausentes, decidiéndose según sea el caso, asegurando la calidad de los resultados. A continuación, la transformación de las variables categóricas mediante técnicas de codificación para convertirlas en formatos numéricos, permitiendo su procesamiento por algoritmos de aprendizaje automático. La normalización de las variables numéricas se llevará a cabo para estandarizar sus rangos, facilitando así la interpretación y el procesamiento analítico. El tratamiento de *outliers* se realizará identificando y gestionando los valores extremos para reducir su impacto distorsionador en los modelos predictivos. Finalmente, se eliminarán las variables no informativas, aquellas que no contribuyen significativamente a nuestro análisis o a la predicción de interés, y así optimizar de esta manera la eficacia de nuestros modelos.

Respecto a la generación de características, cabe destacar que este proceso es crucial para reflejar con precisión la experiencia del paciente en el servicio de urgencias. Desarrollaremos variables de mayor complejidad que capten diferentes aspectos del proceso de atención, incluyendo diferentes formas en los que se pueden expresar situaciones del servicio de urgencia o tiempos de espera, que puedan influir significativamente en la percepción de la calidad del servicio y, por ende, en la lealtad del paciente algunas de estas variables son:

- Tiempos de espera de proceso: A partir de los hitos temporales se obtendrán los tiempos de espera a cada etapa del proceso.

- Abandono sin atención médica (LWBS) La identificación de pacientes que abandonan el servicio de urgencias antes de recibir atención es fundamental, ya que este indicador puede señalar problemas operativos y afectar negativamente la percepción de la calidad y la lealtad hacia el servicio.
- *Overcrowding*: Se realizará un método para valorar el nivel de congestión, basándonos en el número de pacientes en la sala de espera y los boxes al mismo tiempo, lo cual puede afectar la experiencia del paciente y su percepción de la calidad del servicio.
- Capacidad del Servicio de Urgencias y Carga de Trabajo del Personal Médico: Analizaremos la capacidad operativa del servicio de urgencias y la carga de trabajo del personal médico en el momento de la visita, factores críticos que pueden impactar en la calidad de la atención y en la satisfacción del paciente.
- *Boarding*: Determinaremos el tiempo que transcurre desde la decisión de hospitalizar a un paciente hasta que es efectivamente hospitalizado y el box queda disponible, reflejando posibles demoras en el proceso de hospitalización.
- Alteración de Signos vitales.
- Recurrencia: Hace referencia al número de veces que los pacientes previamente han consultado en el SU.

Posterior a la generación de las nuevas características se volverá a analizar estadísticamente la relación entre cada uno de los factores y la lealtad de los usuarios, identificando en una primera instancia las variables que individualmente podrían asociarse con más fuerza a la lealtad.

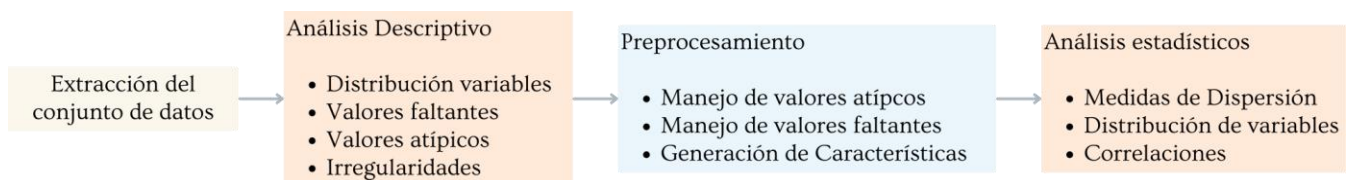


Figura 12. Representación esquemática del flujo de trabajo para la preparación de datos en proyectos de ciencia de datos o investigación aplicada. Incluye la extracción, caracterización inicial, preprocesamiento y reexploración de las variables, asegurando la calidad del dataset para el posterior análisis inferencial o predictivo.

5.2.- Implementación de algoritmos de Aprendizaje de Máquinas de clasificación y regresión para la predicción de lealtad a partir de los datos obtenidos.

En primer lugar, se procederá a dividir el conjunto de datos en tres subconjuntos no superpuestos: 60% para entrenamiento, 20% para validación y 20% para prueba. Esta partición permite implementar un flujo robusto de desarrollo de modelos, donde el conjunto de entrenamiento se utiliza para ajustar los algoritmos y realizar procesos de selección de variables; el conjunto de validación se utilizará para afinar hiperparámetros y finalmente, el conjunto de prueba se reserva para la evaluación final del desempeño del modelo, proporcionando una estimación no sesgada de su capacidad generalizadora. Esta estrategia es particularmente importante en entornos donde la replicabilidad y la inferencia externa son críticas, como es el caso de la predicción de fenómenos complejos como la lealtad usuaria.

Los modelos seleccionados para la tarea de clasificación incluyen Redes Neuronales, que ofrecen la capacidad de modelar complejas relaciones no lineales; XGBoost LightGBM y RF, que han demostrado resultados eficaces en la evidencia disponible y tienen estrategias para evitar el sobreajuste a través del ensamblaje de múltiples árboles de decisión. Además, se utilizará el modelo de regresión RegLog y Elastic Net para explorar otras estrategias disponibles.

Para la selección de las variables, considerando la posible correlación interna entre variables, redundancia de información y variables con bajo poder predictivo, se realizó el método *Forward Selection*. Este método consiste en la implementación del modelo solo con una variable. Este enfoque iterativo evalúa y selecciona las variables de manera incremental, comenzando con la que mayor mejora aporta al rendimiento del modelo. En cada paso se agrega la siguiente variable que optimiza las métricas de evaluación, hasta que no se logran mejoras significativas. Este proceso se realiza con todos los modelos y obtener un conjunto menor de variables único. Posteriormente, para optimizar el rendimiento de los modelos con las variables seleccionadas, se realiza ajuste de hiperparámetros para cada modelo, maximizando su precisión y eficiencia. La validación cruzada será empleada para garantizar

la robustez y la capacidad de generalización de los modelos, evitando el sobreajuste a los datos de entrenamiento.




Figura 13. Flujo de trabajo para la implementación del modelo. Luego de la división del conjunto de datos, se entrenan los modelos con la finalidad de seleccionar las características. Esto se realiza con el conjunto de entrenamiento utilizando validación cruzada en 5 particiones, posteriormente, se utilizará nuevamente validación cruzada y el conjunto de validación para ajustar los hiperparámetros y finalmente se evaluará el modelo con el subconjunto de prueba.

5.3- Medición y comparación el desempeño de los algoritmos implementados.

Para la medición y comparación del desempeño de los algoritmos, hemos decidido utilizar el Área bajo la Curva ROC (AUC ROC) como nuestra principal métrica de rendimiento. Esta decisión se fundamenta en la revisión de proyectos similares dentro del ámbito de estudio se identificó que el AUC y la exactitud son las métricas más comúnmente empleadas. Sin embargo, nuestra elección de favorecer el AUC sobre la precisión se sustenta en la anticipación de un desequilibrio en la distribución de nuestras clases objetivo. Dicho desequilibrio podría distorsionar la interpretación de la exactitud como medida de rendimiento, ya que valores altos podrían reflejar simplemente la prevalencia de la clase mayoritaria sin ofrecer una verdadera comprensión de la capacidad del modelo para identificar correctamente los casos de la clase minoritaria. En contraste, el AUC ROC proporciona una medida más robusta y equitativa del rendimiento del modelo a través de diferentes umbrales de decisión, lo que resulta esencial en nuestro contexto de estudio, donde la correcta clasificación de las clases minoritarias es crítica, como se detalla en el punto 1.2.3 de este documento.

Para establecer objetivos de desempeño para el modelo, se ha decidido fijar el 82% de AUC ROC como el umbral mínimo de rendimiento. Esta cifra se basa en el rendimiento observado en estudios previos de la bibliografía que han investigado la satisfacción, la cual hemos utilizado como un referente, o *proxy*, para la lealtad debido a la ausencia de estudios directamente comparables en nuestro ámbito específico. Esta elección se sustenta en dos consideraciones principales. Primero, aunque la satisfacción y la lealtad no son sinónimos, la satisfacción se reconoce como el indicador más directo y confiable disponible que podemos utilizar para inferir la lealtad. La falta de estudios que aborden directamente la lealtad con las variables clínicas y administrativas específicas a nuestra disposición nos lleva a apoyarnos en la satisfacción como un sustituto razonable, aun reconociendo que no captura completamente la complejidad de la lealtad como concepto.

En segundo lugar, conscientes de que no contamos con datos directos de la experiencia clínica del paciente, elemento central en muchos de los estudios previos sobre satisfacción, hemos decidido establecer el 82% de AUC ROC como objetivo. Esta decisión supone el valor predictivo de los datos clínicos y administrativos a nuestra disposición, pese a la falta del componente de experiencia de usuario, y de medición directa previamente mencionado.

Asumimos que, aunque carecemos de indicadores directos de experiencia clínica, las variables administrativas y clínicas de las que disponemos pueden ofrecer información valiosa para predecir la lealtad. Este enfoque refleja nuestra confianza en que, incluso sin datos sobre la experiencia intrahospitalaria, es posible alcanzar una comprensión significativa de los factores que contribuyen a la lealtad del paciente.

5.4.- Proponer estrategias y recomendaciones basadas en los hallazgos

Para proponer estrategias y recomendaciones basadas en los hallazgos de los modelos predictivos, se seguirá un enfoque que permita identificar las variables más influyentes en la predicción de la lealtad de los pacientes y, a partir de ahí, desarrollar intervenciones que maximicen la eficiencia y efectividad en el contexto clínico. Este enfoque se articula en dos etapas:

En primer lugar, se realizará un análisis de importancia de características. Este análisis tiene como objetivo establecer cuáles son las variables que más contribuyen a la predicción de la lealtad de los pacientes. Para interpretar la contribución individual de cada variable al modelo predictivo, se emplearon valores SHAP (*SHapley Additive exPlanations*), una metodología basada en teoría de juegos cooperativos que permite descomponer la predicción de un modelo en aportes atribuibles a cada característica. Esta herramienta permite identificar no solo las variables más relevantes, sino también el sentido y magnitud de su influencia en cada predicción, proporcionando así interpretabilidad local y global del modelo (53).




Figura 14. Valores SHAP para la interpretación de un modelo de clasificación. El *base rate* (0.1) representa la predicción promedio del modelo en la población general. A partir de este valor, las variables del paciente contribuyen positiva o negativamente hasta alcanzar el *output* individual (0.4), explicando cómo las características específicas afectan la predicción final. La magnitud del valor SHAP implica el poder predictivo, el signo a la clase a la que predice y el color refiere al valor de la variable, un valor rojo es un valor elevado de la variable, por el contrario, un valor azul es un valor bajo. En la imagen, un valor alto de edad (rojo), predice aumenta la predicción de la clase. Obtenida de Lundberg, 2017 (53).

Las variables identificadas como más influyentes serán analizadas desde una perspectiva tanto clínica como de gestión. Esto para asegurar que las recomendaciones propuestas no solo sean estadísticamente válidas sino también razonables desde el punto de vista organizacional.

En una segunda etapa, se propondrán estrategias y recomendaciones basadas en los resultados de la implementación del modelo, evaluando si el modelo construido puede ser utilizado para generar un sistema de soporte a las decisiones y apoyar a autoridades de la institución a tomar

decisiones informadas y personalizadas basadas en datos. Por ejemplo, al identificar pacientes con mayor riesgo de no ser leales, el sistema podría sugerir intervenciones específicas para mejorar su experiencia y satisfacción.

Este enfoque permitirá sugerir a la institución de salud no solo mejorar la satisfacción y lealtad de sus pacientes, sino también entregar herramientas para adaptarse de manera proactiva a los cambios y desafíos que puedan surgir, asegurando una mejora continua en la calidad del servicio ofrecido.

6.- Resultados

6.1.- Generar un conjunto de datos limpio, coherente y preprocesado a partir de la información almacenada en el sistema de información hospitalaria del HCUCH.

6.1.1.- Obtención de datos y Criterios de exclusión

Luego de la aprobación del proyecto por el comité de ética, se procedió a recopilar la información correspondiente a los Datos de Atención de Urgencia (DAU) del SU del HCUCH correspondientes al período 2015-2019. Tras aplicar los criterios de inclusión, quedaron 140.354 registros de atención entre julio de 2015 y diciembre de 2019, excluyendo el primer semestre de 2015 debido a interrupciones importantes y sostenidas en el sistema de información hospitalaria (HIS) durante ese período.

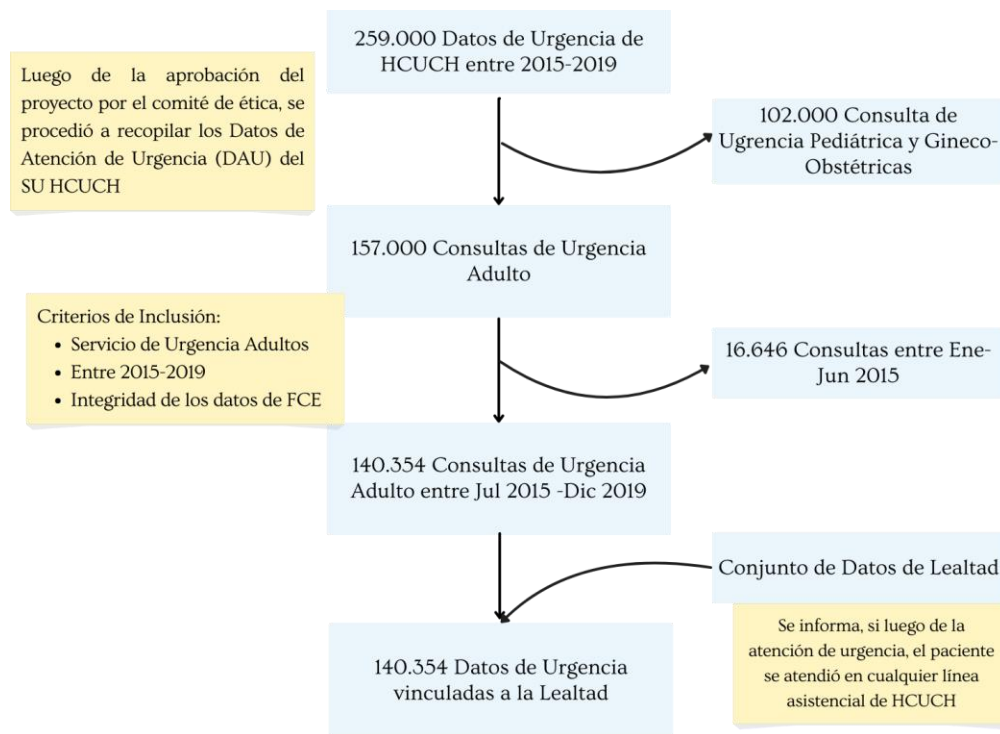


Figura 15. Recopilación y aplicación de criterios de inclusión al set de datos junto a las variables obtenidas. A partir del set de datos, luego de los criterios de exclusión se obtuvo 140.354 atenciones de urgencia adultos entre julio de 2015 y diciembre 2019. Fuente: Elaboración propia.

6.1.2.- Variables

Se obtuvo un total de 27 variables a partir de los DAU, que fueron clasificadas en tres categorías (ANEXO 1-3). La primera categoría considera la información demográfica del paciente, incluyendo variables como la edad, el género, la nacionalidad, comuna de residencia y previsión de salud. Esta información se recoge al momento de la admisión del paciente, junto con la fecha y hora de admisión. La segunda categoría se refiere a la información clínica del paciente, la cual se recopila desde el Triage hasta el alta médica, esto involucra la recolección de diversos datos relevantes, tales como el modo de llegada (por sus propios medios o traído en ambulancia), su nivel de dolor (medido en según Escala Visual Análoga de 1 a 10), y signos vitales (temperatura, presión arterial, saturación de oxígeno, frecuencias cardíaca y respiratoria), además del motivo de la consulta. Posteriormente es evaluado por un médico quien registra un diagnóstico y define el destino del paciente

(domicilio, hospitalización u otro). Finalmente, la tercera categoría corresponde a las variables administrativas del proceso de atención del paciente, obteniéndose la fecha y hora de cada uno de estos momentos, desde admisión hasta egreso y tiempos de hospitalización según sea el caso, junto con otras variables administrativas como el profesional responsable del alta médica, el box en el que se atendió y el servicio en el que se hospitalizó.

	Variables DAU
Demográficas	ID, Edad, Género, Previsión, Comuna, Nacionalidad
Clínicas	Medio de llegada, Triage, Motivo Urgencia, Temperatura, Presión arterial, Frecuencia Cardíaca, Escala de dolor, Diagnóstico, Motivo de alta, Destino
Administrativas	Fecha y Hora de Admisión, Triage, Primera Consulta, Alta, Traslado, Médico Responsable, Box, Servicio de Destino

Tabla 4. Variables obtenidas en el Dato de Atención de Urgencia (DAU) HCUCH. Los datos contienen diferentes variables que fueron categorizadas como Demográficas, Clínicas y relacionadas a hitos temporales. Fuente: Elaboración propia

6.1.3.- Preprocesamiento

Posterior a la extracción del conjunto de datos, se realizó un proceso de análisis y preprocesamiento, dirigido a garantizar la calidad y la consistencia de las variables a utilizar en el análisis posterior, así como para generar características que permitieran representar de forma congruente los fenómenos asociados a la lealtad institucional. Este último paso fue clave para dotar de sentido analítico a los datos crudos, siendo lo que les otorgó mayor relevancia respecto del objetivo del proyecto.

Respecto a la detección y manejo de valores faltantes y atípicos, el detalle específico de las acciones implementadas para cada variable se presenta en los anexos (ANEXO 4-6), donde se documenta, caso a caso, la proporción de datos ausentes, la presencia de valores anómalos y el criterio de manejo adoptado, ya sea mediante eliminación de variables o generación de variables binarias o transformación de variables categóricas mediante codificación *one-hot*. A continuación, las variables con mayor modificación.

Variable	Tipo de Variable	Total NaN	Observaciones
COMUNA	Categórica de Alta Cardinalidad	2055 NaN (1.46%)	Se crearon agrupaciones de comunas para identificar al usuario, siendo cada agrupación una variable. En el caso de que no tenga comuna asociada, tendrá valor 0 en cada una de las variables.
NACIONALIDAD	Categórica de Alta Cardinalidad	2086 NaN (1.49%)	A partir de nacionalidad se creo la variable "Chileno", cuyo valor es = 1 cuando Nacionalidad = Chileno, siendo 0 en todo el resto de los casos, incluyendo NaN.
TEMPERATURA	Continua	7551 NaN (5.38%)	Se crea variable "Fiebre" igual a 1 si Temperatura es mayor a 37.7, todo el resto de los casos, incluido NaN, son 0
EVA	Continua / Entero. Valoración cuantitativa de dolor	22202 NaN (15.82%)	Se crea variable "Dolor" igual a 1 si EVA es mayor a 6, todo el resto de los casos, incluido NaN, son 0
BOX	Categórica de alta Cardinalidad	26132 NaN (18.62%)	Se elimina la variable debido a que por tan alta cantidad de Nan no permite análisis adecuado.
MEDIO DE LLEGADA	Categórica de baja cardinalidad	446 NaN (0.32%)	Se elimina la variable, debido a que todos los pacientes presentan el mismo modo de llegada, por lo que no representa la realidad.
DESTINO	Categórica de Baja Cardinalidad	446 NaN (0.32%)	Se crea una variable por cada Destino posible, en caso de que sea NaN, se observará el Motivo de Alta. Si este es "Mejorado", o "Estabilizado", Destino será = a domicilio, en todos los otros casos su destino será "OTROS"
FECHA.PRIMERA_CONSULTA	Formato Datetime	18495 NaN (13.18%)	Coincide plenamente con los pacientes que abandonan el Servicio de Urgencia sin atención médica. En conjunto con la variable COD_DIAG crean la variable "999" que hace alusión a estos pacientes.
FECHA.EGRESO	Formato Datetime	57 NaN (0.04%)	Alta coincidencia con FECHA.ALTA.MÉDICA, presentando además, un 9.6% de Outliers, evidenciando que en el proceso clínico se dan de alta los pacientes, pero en un porcentaje importante no se quita al paciente del sistema. Variable eliminada.
FECHA.TRASLADO	Formato Datetime	119329 NaN (85.02%)	Es la Fecha en que se traslada a sala, por lo que coincide con los usuarios que fueron hospitalizados. No se utilizará directamente como variable
FECHA.ALTA_HOSP	Formato Datetime	119329 NaN (85.02%)	Es la Fecha de alta de hospitalización, por lo que coincide con los usuarios que fueron hospitalizados. No se utilizará directamente como variable

Tabla 5. Síntesis del manejo de los datos faltantes (NaN). Se indica el tipo de variable, el porcentaje de datos faltantes identificados, y la estrategia aplicada en cada caso, incluyendo eliminación de la variable, creación de nuevas variables derivadas o reclasificación categórica.

La presencia de valores NaN en algunos atributos evidenció debilidades en la calidad del registro clínico. Tal es el caso de variables como "BOX" y "MEDIO_DE_LLEGADA", las cuales fueron excluidas del análisis debido a su elevada incompletitud e inconsistencia, respectivamente, a pesar de su potencial valor informativo para describir el proceso asistencial. Asimismo, se destaca el caso de la variable "FECHA_EGRESO", que, aunque podría haber permitido calcular el tiempo exacto de estancia de los usuarios en el Servicio de Urgencia, presentó valores atípicos extremos —con diferencias que oscilaban entre 10 horas y hasta 10 años posteriores a la "FECHA_ALTA_MEDICA"—, por lo que se optó por su eliminación del conjunto de datos. En contraposición, otros valores faltantes aportaron información significativa para el análisis, como en la variable "FECHA_PRIMERA_CONSULTA_MEDICA", cuyos valores ausentes correspondían a pacientes que abandonaron el Servicio de Urgencia sin ser atendidos (LWBS), constituyendo una característica relevante para el estudio. Respecto al manejo de valores faltantes en otras variables, como se verá en los siguientes párrafos, al generarse variables binarias derivadas a través de *one-hot*, por ejemplo, "Fiebre", "Hipertensión" o "Chileno" solo se codifica con valor positivo (1) la presencia de la condición correspondiente, mientras que la ausencia explícita o implícita (NaN) es interpretada como negativa (0), evitando así problemas de interpretación o imputación inadecuada en dichas variables.

Respecto a la presencia de valores atípicos en el conjunto de datos, dada la naturaleza de las variables disponibles en que la mayoría de las variables correspondían a fechas o a variables categóricas de baja variabilidad, la probabilidad de aparición de outliers fue mínima. Las variables susceptibles de presentar valores extremos fueron la edad y los signos vitales continuos, tales como la frecuencia cardíaca, la temperatura corporal y la presión arterial. En el caso de la edad, se observaron valores altos, aunque plausibles dentro de los rangos esperables para la población general, por lo que no se realizaron transformaciones ni exclusiones adicionales. Por su parte, en los signos vitales no se identificaron valores fuera de los rangos fisiológicamente aceptables, dado que el sistema de información hospitalario (HIS) restringe el ingreso de datos a intervalos previamente definidos como clínicamente válidos. En consecuencia, no fue necesario aplicar procedimientos adicionales de corrección o eliminación de registros por valores atípicos.

A partir de este primer análisis, se procedió a generar nuevas características destinadas a maximizar la información disponible tanto sobre los individuos como sobre su proceso clínico, asegurando al mismo tiempo que dicha información fuera segmentable o agrupable, de modo que pudiera ser reconocida y aprovechada por los algoritmos de aprendizaje automático. Finalmente quedaron 40 variables predictoras que se describen a continuación.

Dentro de la categoría de variables demográficas, se reformuló la variable “Comuna”, la cual, debido a su alta cardinalidad (263 valores distintos), aportaba escaso valor predictivo en su forma original. Por ello, se optó por transformarla en cuatro variables que indicaran si el paciente reside en: la Región Metropolitana (RM), el sector norte de la RM, el sector centro o el sector oriente. De manera similar, la variable “Previsión”, que presentaba también una alta cardinalidad (132 valores distintos), fue reformulada en categorías distinguibles y operativamente relevantes: sin previsión (o Fonasa A, que en la práctica funciona como atención particular dado que no permite acceso a la Modalidad de Libre Elección), Fonasa Libre Elección (tramos B, C y D), Isapre General, Isapre Preferente (convenio con la Universidad de Chile reflejado en el proceso de admisión), Isapre con seguro catastrófico, beneficiarios de prestaciones GES (Garantías Explícitas en Salud) y usuarios con vinculación institucional con la Universidad de Chile, ya sea por su relación con el Hospital Clínico o la universidad (funcionarios y estudiantes). Respecto a las demás variables demográficas, la edad fue normalizada con el objetivo de facilitar su procesamiento por parte de los algoritmos. En cuanto a las variables de género y nacionalidad, ambas fueron tratadas como binarias; en el caso de la nacionalidad, se mantuvo la distinción previamente mencionada entre personas chilenas y extranjeras.




Figura 16. Esquema de transformación y preprocesamiento de las variables demográficas. Se muestra el tratamiento a las variables originales de edad, género, previsión, comuna y nacionalidad, orientado a reducir la cardinalidad y mejorar su interpretabilidad para el modelo predictivo. Fuente: Elaboración propia.

En cuanto a las variables clínicas, se incorporó el nivel de Triage registrado en el DAU, el cual presenta categorías del I al V. Esta variable fue transformada mediante codificación *one-hot*, permitiendo su integración como variable categórica en el modelo. Asimismo, se procesaron los signos vitales capturados al ingreso (temperatura, presión arterial, frecuencia cardíaca y escala de dolor) para generar variables binarias que indicaran alteraciones clínicas específicas, como fiebre, hipertensión, hipotensión y dolor intenso. Adicionalmente, se creó una variable binaria global que indica si al menos un signo vital se encuentra alterado, junto con una variable ordinal que representa el número total de alteraciones detectadas, proporcionando una aproximación a la severidad del cuadro clínico al ingreso. Respecto al Motivo de consulta y Diagnóstico CIE-10, ambos fueron descartados del análisis. En el primer caso, por tratarse de texto libre en lenguaje natural, cuyo procesamiento semántico escapa al alcance del presente proyecto. En el segundo, por la elevada heterogeneidad de códigos y la dificultad para una agrupación clínicamente válida que se relacione de manera directa con la lealtad institucional, a excepción de los pacientes que se retiran sin ser atendidos (LWBS), dado que esta condición queda codificada en el diagnóstico CIE-10, por lo que se creó la variable categórica LWBS. También se incorporó el registro de pacientes fallecidos en el Servicio de Urgencia, aunque no fue posible identificar aquellos que

fallecieron posteriormente en hospitalización, lo cual habría aportado información adicional al modelo. Finalmente, se incluyó el destino del paciente al egreso de urgencias, creando variables mediante codificación *one-hot* para tres categorías: hospitalización (con variables complementarias que indican días de hospitalización y tiempo desde ingreso hasta traslado), alta a domicilio y otros destinos (incluyendo traslados externos, LWBS y rechazos de hospitalización).




Figura 17. Esquema de transformación y preprocesamiento de las variables Clínicas. Se muestra el tratamiento aplicado a las variables clínicas extraídas desde el Servicio de Urgencia, incluyendo Triage, signos vitales, diagnóstico y destino del paciente. Se destacan las transformaciones binarias, categóricas y ordinales, según la naturaleza de cada variable. Fuente: Elaboración propia.

En relación con las variables administrativas y derivadas de hitos temporales, se construyeron distintos indicadores destinados a describir el proceso asistencial en el Servicio de Urgencia, con especial énfasis en aquellos aspectos que podrían tener un impacto en la experiencia del usuario, su satisfacción y, eventualmente, su lealtad hacia la institución. En primer lugar, se generaron variables de tiempo de espera que cuantifican: el intervalo entre la admisión y el Triage, entre el Triage y la primera atención médica, y el tiempo total de permanencia en urgencias (desde la admisión hasta la alta médica). Para los casos que finalizaron en

hospitalización, se añadieron los días totales de hospitalización y el tiempo de traslado entre el alta desde urgencias y el ingreso hospitalario. Adicionalmente, se diseñaron variables orientadas a reflejar la carga asistencial del servicio en el momento de la atención. Se construyó una variable que representa el número total de pacientes presentes en el SU al momento de la admisión de cada paciente, calculada como la cantidad de usuarios admitidos que aún no habían sido dados de alta. A partir de esta, se derivó una segunda variable que identifica cuántos pacientes, en ese mismo instante, se encontraban en espera de su primera atención médica, es decir, aún no habían sido evaluados por un profesional. Se considera que este indicador puede captar indirectamente la percepción de saturación desde la perspectiva del paciente (dado que consistiría en la suma de pacientes en sala de espera). A su vez, se estimó la diferencia entre ambos valores, pacientes totales en urgencias y pacientes en espera de atención, como una medida del nivel de ocupación interna del servicio. Por otra parte, cada episodio de atención está asociado a un médico responsable. Dado que existe rotación frecuente de profesionales, incluyendo médicos en formación, y que el nombre específico no aporta valor predictivo directo, se optó por generar una variable continua que indique el número total de médicos en funciones durante el turno correspondiente, como aproximación a la capacidad operativa del equipo clínico. Asimismo, se incorporó el día de la semana como variable categórica, considerando que la carga asistencial y el flujo de pacientes pueden variar significativamente según el día. Finalmente, se construyó una variable continua que representa el número de consultas previas realizadas por cada paciente durante el periodo observado. Esta variable busca capturar un patrón de comportamiento denominamos recursividad del paciente, entendida como la tendencia a regresar reiteradamente al mismo servicio de urgencia. El análisis de esta recursividad resulta particularmente relevante, ya que puede reflejar tanto una vinculación positiva con el centro asistencial —manifestación de lealtad o confianza— como también una eventual falla en la resolución de problemas clínicos, que obliga a los pacientes a volver. En ambos casos, se trata de un patrón valioso para la comprensión de los determinantes de la lealtad institucional.




Figura 18. Esquema de transformación y preprocesamiento de las variables Administrativas. Se representan las variables derivadas de la información administrativa del proceso asistencial en urgencias, incluyendo tiempos de espera, carga asistencial, duración de hospitalización, dotación médica y número de consultas previas (recursividad del paciente). Fuente: Elaboración propia.

Luego de generadas las variables emergieron nuevos valores atípicos, principalmente asociados a los tiempos de atención y hospitalización. Tal como se había detectado en análisis exploratorios previos, algunas diferencias horarias resultaban incompatibles con el flujo real del proceso clínico. Un ejemplo claro fue la incongruencia entre la fecha de alta médica y la fecha de egreso, motivo por el cual se optó por excluir esta última del análisis, al considerarse poco confiable como variable. Coherente con esa evidencia en el análisis previo, aparecieron registros con duraciones excepcionales, como procesos de atención médica que se extendían por más de siete días y hospitalizaciones superiores a los seis meses. Con base en el conocimiento del funcionamiento interno del hospital, se reconoce que este tipo de casos, aunque poco frecuentes, son posibles y clínicamente explicables. Sin embargo, con el objetivo de favorecer la robustez y el rendimiento del modelo predictivo, se decidió aplicar

una estrategia de *winsorización* sobre las variables temporales. En concreto, se truncaron los valores por sobre el percentil 99, reasignando estos casos al valor exacto de dicho percentil. Esta transformación se aplicó antes del proceso de estandarización, de modo de limitar la influencia de valores extremos sin distorsionar la estructura general de la distribución.

6.1.4.- Análisis Descriptivo y Univariado

Luego del preprocesamiento, con la consecuente generación de características, se realizó un análisis descriptivo general de la muestra, con el objetivo de caracterizar la distribución de cada una de las variables consideradas para la modelación. Posteriormente, se procedió a examinar la asociación entre cada variable predictora y la variable objetivo de este estudio, es decir, la lealtad del paciente, operacionalizada como una variable dicotómica. La elección de las pruebas estadísticas utilizadas dependió del tipo de variable analizada. Para las variables continuas (como la edad o los tiempos de proceso), se utilizaron pruebas no paramétricas, como U de Mann–Whitney, dado que no se pudo asumir normalidad en la mayoría de los casos. Para las variables categóricas o binarias, se aplicó Chi-cuadrado (χ^2) para determinar significancia estadística y se complementó con el cálculo del coeficiente ϕ (phi) como medida de fuerza de asociación. Con el fin de facilitar su interpretación y análisis, las variables se agruparon como se han venido agrupando hasta el momento, según variables demográficas, clínicas y administrativas. El análisis exhaustivo con todas las variables se presenta en anexos (ANEXO 7-9) y a continuación se presentan las variables que mostraron mayor significancia estadística o relevancia clínica potencial, ilustradas con gráficas interpretativas y tablas resumen.

Respecto a las características demográficas de la población estudiada, la edad promedio de los pacientes fue de 46,5 años, con una desviación estándar de 20,1 años, siendo el 97,6 % de los usuarios de nacionalidad chilena. En relación con la previsión de salud, el 46,0 % de los pacientes se encontraba afiliado a Fonasa, seguido por usuarios con Isapre con convenio preferente (26,4 %), Isapre sin convenio preferente (19,4 %), particulares (3,7 %), afiliados institucionales UCHILE (3,0 %), GES (0,4 %) y CAEC (0,3 %). Si bien estas últimas características representan a un porcentaje pequeño de la muestra, fueron relevadas por

considerarse que podrían impactar positivamente con la lealtad, elemento que se evidencia en el análisis univariado. Respecto a la comuna de residencia, el 95,0 % de los pacientes provenía de la Región Metropolitana, destacando un 45,7 % correspondiente al sector norte de Santiago, correspondientes a las comunas del Servicio de Salud metropolitano Norte. Solo un 6,9 % residía en comunas del Servicio de Salud Metropolitano Central, y un 1,3 % en comunas del sector oriente (COM_ABC1). En cuanto a la relación con la lealtad, se observaron diferencias estadísticamente significativas en todas las variables demográficas analizadas, aunque con asociaciones de baja magnitud. En general, los pacientes de mayor edad, con previsión preferente o institucional, y aquellos residentes en áreas de captación directa del hospital, tendieron a mostrar mayores tasas de lealtad hacia la institución.




Figura 19. Porcentaje de lealtad según características demográficas seleccionadas (izquierda) y distribución de edades por grupo de lealtad (derecha). Se observa que ciertas variables presentan diferencias marcadas en la proporción de pacientes leales, por ejemplo, en usuarios con cobertura institucional o convenios preferentes, así como en pacientes con seguro GES o catastrófico (CAEC). A su vez, la distribución de edad muestra que los pacientes leales tienden a ser mayores, con un segundo pico de densidad en torno a los 60 años. Si bien todas las asociaciones son estadísticamente significativas, su fuerza es baja, lo que sugiere que estas variables deben analizarse en conjunto con factores clínicos y asistenciales para comprender plenamente su influencia en la lealtad. Fuente: Elaboración propia.

Respecto a las características clínicas y del proceso de atención, se observó que el 41,9 % de los pacientes presentó alguna alteración de signos vitales. Entre los signos específicos, la hipertensión fue la más frecuente (20,2 %), seguida por hipotensión (9,2 %), dolor (14,5 %),

fiebre (1,8 %) y taquicardia (3,7 %). Sin embargo, en todos los casos la relación con la lealtad fue débil o muy débil: los pacientes con estos signos mostraron tasas de lealtad cercanas al promedio, en torno al 70 %. En cuanto a Triage, la mayoría de las atenciones fueron clasificadas como Triage III (64,9 %), seguidas por Triage II (19,4 %) y Triage IV (13,7 %). Las categorías I y V fueron poco frecuentes. La lealtad fue más alta en Triage II (74,9 %) y más baja en Triage V (38,0 %), lo que sugiere que tanto los casos de menor gravedad como los más inusuales podrían tener un vínculo más débil con la institución. Desde el punto de vista del proceso de atención, un 15,6 % de los pacientes fue hospitalizado, 65,4 % fue dado de alta a domicilio y un 19,1 % tuvo un destino diferente, como rechazo de hospitalización, alta voluntaria, traslado a otro centro o se fue sin ser atendido LWBS. Respecto a este último, un 14,5 % de los pacientes efectivamente fue categorizado como LWBS y mostraron la menor proporción de lealtad (26,6 %) de todas las características, en contraste con quienes fueron hospitalizados, cuya lealtad alcanzó el 91 %. Quienes fueron dados de alta también presentaron una tasa elevada (72,2 %), mientras que los que presentaron otro destino de egreso mostraron una tasa reducida de lealtad (35,3 %).




Figura 20. Relación entre características clínicas, destino del paciente y lealtad a la institución. La figura muestra la distribución de los niveles de Triage al ingreso, donde destaca la concentración de pacientes en categoría III (65 %) y II (20 %). Luego se representa el destino final tras la atención, siendo el alta a domicilio la más frecuente (65 %), seguida por otro destino (19 %) y finalmente hospitalización (16 %). Además, se observa el porcentaje de lealtad según distintas variables clínicas y del proceso. La Hospitalización y el Triage II se asocian a las tasas más altas de lealtad (91 % y 75 % respectivamente), mientras que el abandono sin atención médica (LWBS, 27 %) y el triage V (38 %) muestran las más bajas. Todas estas variables mostraron asociaciones estadísticamente significativas con la lealtad, pero con baja fuerza de asociación, a excepción de Hospitalización y LWBS, que presentaron moderada fuerza de asociación. Fuente: Elaboración propia.

Finalmente, respecto a las variables administrativas y de contexto del proceso, se observó, que al momento del ingreso, el número promedio de pacientes en el SU era de 17,2 (DE $\pm 7,3$), con una mediana de 17. De ellos, en promedio 10,4 se encontraban siendo atendidos y 6,8 estaban esperando evaluación médica. Se identificó una correlación negativa entre el número de pacientes presentes en el sistema (tanto recibiendo atención como esperándola) y la lealtad, con coeficientes cercanos a $-0,11$, lo que sugiere que el *Overcrowding* como variable única se asocia a una menor probabilidad de retorno futuro. En cuanto a los tiempos del proceso, el promedio desde el ingreso hasta el Triage fue de 9,8 minutos (DE $\pm 22,2$), mientras que entre el Triage y la Primera Atención Médica fue de 53,6 minutos (DE $\pm 86,8$). El tiempo total de permanencia en urgencias alcanzó un promedio de 3,9 horas. Si bien todos estos tiempos mostraron diferencias significativas entre pacientes leales y no leales, su correlación fue en general débil. Desde el punto de vista del equipo clínico, el número de médicos disponibles en el turno fue en promedio 13,4 (DE $\pm 2,9$), sin mostrar relación significativa con la lealtad. El promedio de días hospitalizado fue de 1,4 (DE $\pm 7,1$), el tiempo hasta el traslado a hospitalización fue de 0,59 horas (DE $\pm 3,5$). Finalmente, se consideró la variable recurrencia que corresponde al número de consultas previas que el paciente había realizado en el sistema de urgencias del hospital antes del episodio actual. El promedio fue de 0,62 consultas previas (DE $\pm 1,5$), con una mediana de 0, lo que indica que una gran proporción de pacientes no presentaba visitas anteriores. No obstante, al analizar su relación con la lealtad, se observó una correlación positiva significativa ($r = 0,15$), siendo una de las más altas entre todas las variables evaluadas. Esto sugiere que la experiencia acumulada con la institución, incluso antes del episodio actual, tiene un efecto positivo sobre la probabilidad de que el paciente vuelva a consultar, reflejando un vínculo previo que puede actuar como predictor de fidelización.




Figura 21. Relación entre carga del SU y la Recurrencia con la lealtad institucional. A la izquierda, se muestra la distribución del número de pacientes en el SU al momento del ingreso, según si los pacientes fueron leales: a mayor congestión se produce una caída en la lealtad. A la derecha, se presenta la lealtad según el número de consultas previas en el mismo servicio: la lealtad aumenta de forma progresiva con la recurrencia, desde un 63 % en pacientes sin consultas anteriores, hasta un 89 % en aquellos con tres o más visitas previas. Fuente: Elaboración propia.




Figura 22. La figura presenta los coeficientes de correlación más relevantes entre las variables independientes del modelo y la variable de lealtad. Se observa que los factores más fuertemente asociados positivamente a la lealtad fueron la Hospitalización ($\varphi = 0,21$), el haber tenido consultas previas (Recurrencia, $\varphi = 0,15$), los pacientes con Otro destino ($\varphi = -0,34$) y los pacientes LWBS ($\varphi = -0,37$), siendo este último el que presenta asociación más fuerte de todo el set de variables. Fuente: Elaboración propia.

6.1.5.- Análisis de Multicolinealidad

El diagnóstico de colinealidad permite promover la eficacia del modelo, minimizando el riesgo de sobreajuste y facilitando la interpretación clínica de los resultados, así como entregar valiosa información del fenómeno que se está estudiando. Es por esta razón, que se realizó una matriz de correlaciones entre las variables predictoras (ANEXO 10), que confirma varias hipótesis sobre el servicio y, al mismo tiempo, confirma la existencia de multicolinealidad en algunas variables de nuestro set de datos. En primer lugar, la carga asistencial, expresada como número de pacientes en el SU, muestra una asociación moderada con el tiempo transcurrido entre el Triage y la primera atención médica ($r=0,36$), corroborando que la espera prolongada es, con alta probabilidad, efecto de la congestión de pacientes. Esa misma carga se relaciona positivamente con el abandono sin atención (LWBS) ($r=0,30$), mientras que el tiempo hasta la primera atención se correlaciona de modo inverso con LWBS ($r=-0,15$). Esto puede interpretarse como, que los pacientes tienden a marcharse cuando perciben aglomeración, y lo hacen antes de acumular un gran tiempo de espera, y que, al retirarse son pesquisados por admisión en muchos casos y egresados del sistema. En cuanto al perfil del paciente, la edad presenta correlación positiva con la hospitalización ($r=0,20$) y negativa con el alta domiciliaria ($r=-0,15$), reflejando mayor complejidad clínica entre los adultos mayores. Este grupo, además, exhibe una leve tendencia a la lealtad, ya sea por mayor frecuencia de consultas o por preferencias de continuidad asistencial. Por último, el tiempo total de estancia en urgencias (Tiempo_SU) se asocia positivamente con la hospitalización ($r=0,13$) y negativamente con el alta domiciliaria ($r=-0,08$), lo que es coherente con la estadía prolongada que precede al ingreso. Estos vínculos ponen de manifiesto dependencias sustanciales entre variables que eventualmente podrían no aportar en un modelo. En consecuencia, podría justificarse un procedimiento de selección de características destinado a retener sólo los predictores no redundantes y garantizar así la estabilidad y la interpretabilidad del modelo final.

6.2.- Implementación de algoritmos de Aprendizaje de Máquinas de clasificación y regresión para la predicción de lealtad a partir de los datos obtenidos.

6.2.1.- División del Conjunto de datos

Para la implementación de los diferentes modelos se realizó una división estratificada del conjunto de datos en tres subconjuntos no solapados: 60 % para entrenamiento, 20 % para validación y 20 % para prueba, utilizando una semilla aleatoria específica para asegurar la reproducibilidad del experimento. El subconjunto de entrenamiento (60 %) se utilizó exclusivamente para entrenar los modelos iniciales sin ajuste de hiperparámetros y realizar la selección de variables mediante *Forward Selection* como se explicó en el punto 5.2, utilizando internamente validación cruzada de 5 particiones. El subconjunto de validación (20 %) se utilizó para realizar el ajuste de los hiperparámetros y comparar el rendimiento de distintas configuraciones, sin comprometer el set final de evaluación. Finalmente, el 20 % reservado como conjunto de prueba se mantuvo completamente aparte durante todas las etapas de entrenamiento y ajuste.




Figura 23. División del conjunto de datos en 3 subconjuntos. Fuente: Elaboración propia.

6.2.2.- Selección de Características

Como se mencionó en el punto 5.2, se incluyó diferentes modelos de clasificación, algunos modelos basados en árboles (Random Forest, XGBoost, LightGBM), regresiones (Regresión Logística L2 y Elastic Net) y redes neuronales. Para cada uno de estos modelos, con

excepción de las redes neuronales, se aplicó un proceso de *Forward Selection* con validación cruzada de 5 pliegues (CV=5), utilizando el Área bajo la curva ROC como métrica de desempeño. En el caso de las redes neuronales, se redujo la validación cruzada a 3 pliegues (CV=3) debido al tiempo de cómputo significativamente mayor asociado al entrenamiento de este tipo de modelos. Este procedimiento permitió construir, para cada algoritmo, un subconjunto de variables ordenadas según su contribución incremental al rendimiento predictivo, como puede observarse en la Figura 22.




Figura 24. Área bajo la curva ROC (ROC AUC) de cada modelo, agregando una a una la característica que más aumenta el ROC AUC en cada iteración, proceso realizado para la selección de características (*Forward Selection*). La línea vertical se encuentra en la característica número 25, posterior a esa, no hubo un aumento importante del desempeño. Fuente: Elaboración propia.

Una vez obtenidas las variables más relevantes para cada modelo, se compararon los resultados con el objetivo de construir una lista consolidada. Esta lista se basó en un enfoque de consenso por frecuencia y peso predictivo, priorizando aquellas variables que aparecieron consistentemente entre las más relevantes de múltiples modelos y que, además, exhibieron una alta magnitud de impacto en las métricas. Así, se definió un conjunto final de 25 variables predictoras, que capturan tanto las características clínicas, demográficas del paciente como

aspectos contextuales del proceso de atención, y que fueron utilizadas en la siguiente fase de entrenamiento y validación.

Categorías	Variables Seleccionadas			
Demográficas	Edad	Previsión FONASA	Comunas Sector Norte	Particular o FONASA A
	Género	ISAPRE Preferente	Comunas Sector Oriente	Patología GES
	Región Metropolitana	Isapre General	Comunas Centro	Institucional UCHILE
Clínicas	TRIAGE = I	Días de Hospitalización	TRIAGE = V	Alta Domiciliaria
	TRIAGE = II	Otro Destino	Hospitalización	LWBS
Administrativas	Tiempo Admisión - Triage	Tiempo total SU	Tiempo Triage - Atención Médica	Recurrencia

Tabla 6. Conjunto final de variables seleccionadas mediante *Forward Selection* en todos los modelos. Listado de variables seleccionadas como predictores finales tras la aplicación de la técnica de *Forward Selection* en los distintos modelos implementados. Fuente: Elaboración propia.

6.2.3.- Ajuste de Hiperparámetros

Luego de obtener el conjunto de 25 variables se optimizó cada algoritmo mediante el ajuste de hiperparámetros siguiendo un esquema mixto de búsqueda aleatoria y *Greedy*. En primer lugar, se exploró el espacio completo con 80-100 combinaciones aleatorias evaluadas en el subconjunto de validación, identificando la mejor quinteta de resultados, para posteriormente desplazar cada parámetro $\pm$ un paso (o $\pm 15\%$ en continuos) en una barrido densa. Esta doble estrategia intenta capturar la variabilidad global, luego obtener incrementos finos sin un crecimiento exponencial del coste computacional que significaría evaluar todas las opciones posibles. En la Tabla 7 se presentan los rangos iniciales y la descripción funcional de los hiperparámetros explorados para cada modelo, los cuales son expresados con mayor detalle en el ANEXO 11.

Modelo	Hiperparámetros (rangos de la fase aleatoria)	Significado - impacto principal
XGBoost	n_estimators [150-600]; max_depth [3-10]; learning_rate [0.01-0.3]; subsample [0.5-1]; colsample_bytree [0.4-1]; gamma [0-5]; min_child_weight [1-10]	Control del número, tamaño y regularización de los árboles (capacidad del ensamble; prevención de overfitting).
LightGBM	n_estimators [150-600]; num_leaves [20-120]; max_depth [-1, 4-12]; learning_rate [0.01-0.3]; feature_fraction [0.5-1]; bagging_fraction [0.5-1]; lambda_l1/l2 [0-1]	Equilibrio entre complejidad de los árboles hoja-a-hoja y regularización L1/L2.
Random Forest	n_estimators [200-800]; max_depth [4-20, None]; max_features ['sqrt', 'log2', 0.5-1]; min_samples_split [2-20]; min_samples_leaf [1-10]; bootstrap [True, False]	Diversidad de árboles y tamaño mínimo de partición (sesgo-varianza).
Regresión Logística (L2)	C [0.001-100] (log-uniforme), solver ['lbfgs', 'saga']	Peso relativo de la penalización L2 sobre los coeficientes.
Regresión Logística (Elastic-Net)	C [0.001-100]; l1_ratio [0.05-0.95]	Mezcla de penalización L1/L2 que induce esparsidad.
MLPClassifier	hidden_layer_sizes [(64,), (128,64), (128,64,32)]; activation ['relu', 'tanh']; alpha [1e-5-1e-2]; learning_rate_init [1e-4-5e-2]; batch_size [64,128,256]; solver ['adam', 'lbfgs']	Arquitectura y regularización de la red; velocidad de aprendizaje.

Tabla 7. Hiperparámetros ajustados según cada modelo. Cada modelo presenta diferentes hiperparámetros según su arquitectura. La última columna explica en términos generales qué significa cada uno de los hiperparámetros. Fuente: Elaboración propia.

Luego del ajuste de hiperparámetros, se evaluó el impacto del proceso sobre el rendimiento de cada modelo utilizando el conjunto de validación. La Tabla 8 presenta los valores de AUC después del ajuste, junto con la mejora absoluta y su correspondiente porcentaje relativo de incremento. En el ANEXO 12 los hiperparámetros que mostraron mejor rendimiento.

Modelo	AUC (antes)	AUC (después)	Mejora absoluta	Mejora relativa (%)
XGBoost	0.747	0.764	+0.017	+2.28 %
LightGBM	0.744	0.759	+0.015	+2.02 %
Random Forest	0.738	0.751	+0.013	+1.76 %
Logistic (L2)	0.721	0.726	+0.005	+0.69 %
Elastic-Net	0.725	0.732	+0.007	+0.97 %
MLP	0.731	0.743	+0.012	+1.64 %

Tabla 8. Mejora del rendimiento tras ajuste de hiperparámetros en validación. Comparación del AUC obtenido por cada modelo después del ajuste utilizando el subconjunto de validación. Se incluye la ganancia absoluta y el porcentaje relativo de mejora. Fuente: Elaboración propia.

6.3.- Medición y comparación el desempeño de los algoritmos implementados.

6.3.1.- Comparación curva ROC AUC de todos los algoritmos implementados

Tras determinar los hiperparámetros óptimos en la fase previa, se realizó la evaluación definitiva de los modelos predictivos. En esta etapa final, cada algoritmo se entrenó nuevamente desde cero utilizando el 80 % del conjunto original, combinando para ello las particiones previamente destinadas al entrenamiento y la validación, pero conservando intacto el 20 % restante (conjunto de prueba). Esta estrategia busca proporcionar una estimación más precisa y confiable del desempeño real que cada modelo tendrá al ser implementado en producción, disminuyendo así el sesgo asociado al ajuste fino excesivo realizado durante la optimización de hiperparámetros. Finalmente, para facilitar una comparación homogénea y detallada entre los distintos clasificadores, se generaron las curvas ROC completas bajo estas condiciones controladas, cuyos resultados se pueden observar en la Figura 23.




Figura 25. Comparación de curvas ROC para los modelos evaluados en el conjunto de prueba (20 %). Cada curva representa el desempeño discriminativo de un clasificador, es decir, su capacidad para distinguir entre pacientes leales y no leales. El modelo XGBoost obtuvo el mejor rendimiento con un AUC de 78,2%. La línea diagonal gris representa un modelo sin capacidad predictiva (clasificación aleatoria). Fuente: Elaboración propia a partir de la biblioteca matplotlib de Python 3.8.

6.3.2.- Análisis de la estabilidad del desempeño con diferentes inicializaciones

Con el objetivo de medir la estabilidad del desempeño se aislaron los tres algoritmos con mayor AUC y se sometieron a diferentes inicializaciones de las fuentes de aleatoriedad del proceso. Esto se realizó generando 45 nuevos subconjuntos diferentes de entrenamiento y prueba a partir conjunto original y se reentrenó cada nuevo subconjunto con los modelos cuyos hiperparámetros ya se encuentran ajustados. Tras cada réplica se calculó el ROC AUC sobre la nueva partición de prueba y se almacenó el resultado.




Figura 26. Variabilidad del desempeño (ROC AUC) de los modelos XGBoost, LightGBM y NeuralNet a través de 45 diferentes inicializaciones (semillas). Se observa que XGBoost obtuvo un AUC promedio de 77,68 % ($\pm 0,24$), seguido por LightGBM con 77,64 % ($\pm 0,25$) y NeuralNet con 77,57 % ($\pm 0,25$). Aunque las diferencias absolutas son pequeñas, las comparaciones muestran que tanto LightGBM como NeuralNet presentan desempeños estadísticamente inferiores a XGBoost ($p < 0,001$, *t-student*). Esto sugiere una superioridad robusta de XGBoost en términos de estabilidad y rendimiento predictivo bajo múltiples inicializaciones. Fuente: Elaboración propia a partir de la biblioteca matplotlib de Python 3.8.

La Figura 24 concentra los 45 valores de AUC obtenidos tras intercambiar las particiones de entrenamiento y prueba. Los diagramas de caja muestran que XGBoost conserva la media

más alta y la desviación estándar más pequeña, demostrando un mejor desempeño y menos sensible a la aleatoriedad. Una prueba *t* de *Student*, precedida de la verificación de normalidad con Shapiro-Wilk, confirma que su ventaja frente a LightGBM y la red neuronal es estadísticamente significativa ($p < 0,001$). Cabe destacar, además, que los valores AUC presentados en la Figura 23 para cada modelo se ubican en el límite superior de cada caja, lo que revela un leve sesgo optimista inducido por el ajuste de hiperparámetros sobre la partición original, que, al redistribuir los datos, la media de AUC cae medio punto porcentual. Aun así, XGBoost se mantiene en niveles aceptables, respaldando su selección final al combinar precisión elevada con una baja variabilidad intrínseca.

6.3.3.- Detalles del desempeño del modelo de mejor rendimiento: XGBoost

El modelo XGBoost entrenado con las 25 variables seleccionadas alcanza una exactitud global de 0,76 y un ROC AUC de 0,78, lo que refleja una capacidad discriminativa moderadamente alta cuando se consideran todos los umbrales posibles.

		Predicción	
		0	1
Real	0	3536	5428
	1	1390	17717

	Precisión	Sensibilidad	F1-score
No Leal	0.72	0.40	0.51
Leal	0.77	0.93	0.84
	Exactitud	0.76	
	ROC AUC	0.78	

Figura 27. Matriz de confusión (izquierda) y resumen de métricas por clase junto con exactitud y ROC AUC (derecha) obtenidas a partir del modelo XGBoost entrenado sobre las 25 variables seleccionadas para predecir la lealtad de los pacientes. Fuente: Elaboración propia.

Pese a este aceptable resultado global, el desempeño por clase es marcadamente asimétrico. Para la clase 1, correspondiente a los pacientes leales, el algoritmo identifica correctamente al 93% de quienes volverán a consultar (sensibilidad = 0,93), sin embargo, una especificidad del 40%. Por el contrario, la clase la clase 0, aquella que agrupa a los pacientes no leales, el modelo sólo reconoce al 40 % de estos usuarios (sensibilidad = 40%), pero con una

especificidad del 93%. Esta diferencia en la capacidad de distinguir la clase 1 sobre la clase 0 tiene un impacto significativo al momento de trasladar el modelo al mundo real, pues se demuestra que el modelo tiene tendencia a tomar a muchos pacientes no leales como si fueran leales, y por lo tanto quedarían fuera ante una eventual estrategia de retención aplicada sobre ellos, elemento que se considerará en el punto 6.4.3 cuando se aborden posibles estrategias para el cultivo de la lealtad a la institución de salud.

6.4.- Identificación de las variables predictoras más importantes y proporcionar sugerencias basadas en estos hallazgos para promover la lealtad al establecimiento

6.4.1 Identificación de predictores relevantes

Para proponer estrategias y recomendaciones basadas en los hallazgos de los modelos predictivos, se identificó las variables más influyentes en la predicción de la lealtad de los pacientes y, a partir de ahí, sugerir posibles intervenciones que maximicen la eficiencia y efectividad en el contexto clínico. Para esto se realizó un análisis de importancia de características a través de la obtención de valores SHAP (SHapley Additive exPlanations), como se explicitó en el punto 5.4.




Figura 28. Valores SHAP del modelo XGBoost. El eje horizontal representa la influencia de cada característica en la predicción del modelo: valores hacia la derecha aumentan la probabilidad de predecir la clase lealtad, y valores hacia la izquierda la disminuyen. Los puntos rojos indican valores altos de la característica, mientras que los azules representan valores bajos de la misma. Fuente: Elaboración propia a partir de la biblioteca SHAP de Python 3.8.

El gráfico de valores SHAP de la Figura 25 abre varias líneas de análisis que se presentan a continuación. En primer lugar, se confirma nuevamente que el abandono sin atención (LWBS) actúa como un lastre consistente, pues prácticamente todos sus puntos se ubican a la izquierda y con muy poca dispersión, lo que indica que, sin importar el contexto, la fuga reduce drásticamente la lealtad de los usuarios. Por el contrario, la recursividad, la hospitalización y los días de estancia desplazan la nube hacia la derecha y muestran un abanico amplio, lo que sugiere un efecto positivo casi lineal: cuantas más visitas previas o mayor exposición intrahospitalaria, más probable es que el paciente siga recurriendo al establecimiento.

En segundo lugar, el modelo revela que la pertenencia o afinidad con el HCUCH, ya sea previsional, institucional o geográfica, funciona como un potente refuerzo de la lealtad. Los beneficiarios de Isapre Preferente concentran sus puntos rojos en la zona positiva, reflejando la influencia de los convenios que reducen copagos y limitan la red de atención, mecanismos que generan consolidación de la lealtad mediante un costo mayor en las alternativas. De modo similar, la variable Institucional UChile, que agrupa a funcionarios y estudiantes de la Universidad, desplaza sus valores hacia la derecha, sugiriendo que la identidad corporativa y los beneficios internos (aranceles preferentes, cobertura de salud ocupacional) fortalecen el compromiso con el hospital. La proximidad geográfica también se manifiesta en los pacientes de las comunas del Sector Norte, quienes, pese a su menor nivel socioeconómico, presentan valores SHAP uniformemente positivos, contrastando con la de los pacientes FONASA y Particulares, cuyas nubes se agrupan alrededor del cero o levemente hacia la izquierda.

6.4.2 Estrategias y abordajes posibles para el cultivo de la lealtad institucional en función de los predictores

Una primera vía costo-efectiva consiste en atacar el mayor determinante negativo identificado: los pacientes LWBS. Implementar, por ejemplo, un protocolo de *fast-track* para pacientes de baja complejidad, basado en reordenar flujos y habilitar boxes polivalentes en horario punta, requiere principalmente reorganización operativa más que inversión de capital, y la literatura muestra reducciones de hasta 40 % en abandonos con este tipo de medidas (54–56). El mismo esquema puede reforzarse con mensajes de espera estimada en pantallas y notificaciones móviles, herramientas de muy bajo costo que, al ofrecer certidumbre temporal, disminuyen la frustración y, por ende, la probabilidad de abandono(57).

En paralelo, los hallazgos sustentan la expansión de los convenios preferentes con Isapre, ya que el efecto positivo de esta cobertura supera con creces al de otras provisiones. Negociar copagos preferentes o cuotas de afiliación corporativa requiere más gestión que gasto directo y genera un retorno rápido: cada paciente fidelizado bajo este régimen tiende a concentrar la totalidad de sus futuras prestaciones en el HCUCH.

Por último, si bien las comunas del sector norte de la Región Metropolitana ya exhiben lealtad importante, una estrategia que potenciaría este vínculo ya se llevó a cabo por las autoridades del HCUCH y quedó consagrado en la Ley 21.621, promulgada por el Presidente Gabriel Boric el 9 de noviembre de 2023 y publicada en el Diario Oficial el 24 de noviembre de 2023. La norma fortalece el vínculo entre el HCUCH y el Sistema Nacional de Servicios de Salud, restableciendo formalmente su rol histórico como hospital universitario público de referencia para la zona norte de Santiago. Al articular al HCUCH con la red asistencial, sin afectar su autonomía, la ley garantiza financiamiento basal, flujos de derivación preferente y una cartera de atención de alta complejidad que beneficia directamente a las comunas aledañas, según confirma la propia institución (58,59). En la práctica, el nuevo marco legal convierte la proximidad física en un derecho, y sin duda reforzará la inclinación natural a volver al mismo centro. La Ley HCUCH, al consolidar una relación que existía de facto, transforma la afinidad geográfica en un compromiso bidireccional sustentado por normas y recursos, creando así un círculo virtuoso: la población mantiene su preferencia por el establecimiento, y el hospital —ahora integrado a la red— puede responder con mejores tiempos, continuidad y complejidad resolutive, reforzando todavía más la fidelización observada.

6.4.3 Estrategias y abordajes posibles para el cultivo de la lealtad institucional en función de la capacidad predictiva del modelo

Ahora, considerando que el modelo entrega, para cada paciente que egresa del servicio de Urgencia, la predicción de si va o no regresar al HCUCH con nivel de desempeño del 78%. Esa predicción puede traducirse en estrategias dependientes del umbral que uno desee utilizar en el modelo. Es por ello, que una estrategia a dos niveles podría resultar costo-efectiva. Con un umbral bajo, es decir, con una sensibilidad alta (cercana al 80%) pero una especificidad regular (cercana al 50%), podría pensarse en intervenciones de bajo costo, pero pensadas a un alto volumen de personas, como mensajería o descuentos menores, para promover la lealtad con bajo costo unitario. Por el contrario, para intervenciones de mayor costo, como consultas de morbilidad o exámenes a menor, convendría elevar el umbral al punto de prácticamente no encontrar falsos negativos. Este planteamiento maximiza el alcance de las

medidas preventivas sin comprometer la viabilidad financiera. De esta manera, cultivar la lealtad de los usuarios de la manera más eficiente posible.

7.- Discusión

7.1.- Análisis de diferencias con el estado del arte: Logros y limitaciones del proyecto

Los estudios que pronostican satisfacción usuaria a partir de datos clínicos fueron un referente significativo al momento de plantear este proyecto. El contraste de estos trabajos, que predicen satisfacción usuaria al alta hospitalaria con un AUC superior a 82%, deja en evidencia que la meta de este proyecto no era alcanzable aún para este contexto y con la información que se dispuso para su realización. Las causas de esta diferencia pueden residir en lo siguiente y se resumen en la Tabla 9 .

Características	Estado del Arte: Predicción de Satisfacción (ROC AUC >82%)	Predicción de Lealtad (ROC AUC 78%)
Contexto de medición	Al alta hospitalaria	Al egreso de urgencia
Predictores	Demográficas, Clínicas, Hitos Temporales, Encuestas	Demográficas, Clínicas, Hitos Temporales
Variable a predecir	Satisfacción usuaria (medición directa)	Lealtad (medición indirecta)

Tabla 9. Diferencias fundamentales entre proyectos cuyo objetivo es predecir la satisfacción usuaria y el presente proyecto de predicción de lealtad. Se destacan diferencias tanto en contexto de medición, algunos predictores, y el momento de medición de la variable a predecir. Fuente: Elaboración propia.

En primer lugar, existe una diferencia sustancial tanto en el momento como en la forma de medir la variable objetivo. Los modelos del estado del arte asignan su etiqueta después de varios días de hospitalización, lo que brinda al paciente la oportunidad de formarse un juicio reposado sobre el entorno físico, la calidez del trato y la competencia profesional. Esas

percepciones se capturan con precisión mediante una encuesta de satisfacción aplicada al alta. En cambio, nuestro modelo emite la predicción justo cuando el usuario abandona la urgencia, un instante en que la experiencia acaba de concluir, disponiendo de mucha menos información sobre la institución. Y más importante aún, la lealtad se mide indirectamente a través del retorno posterior al proveedor, lo que abre la posibilidad de etiquetar como no leales a pacientes satisfechos que, simplemente, no necesitaron consultar de nuevo durante el periodo de seguimiento.

La segunda diferencia estructural radica en la naturaleza de los predictores. Los trabajos que modelan satisfacción disponen, además de información clínica y administrativa comparable a la nuestra, de la voz del paciente, obtenida mediante cuestionarios estandarizados que exploran la calidad del trato, entre otras percepciones valiosas, que se convierten en variables de gran poder explicativo. El DAU carece de esta capa perceptual, apoyándose sobre hitos administrativos y algunos parámetros clínicos que, no alcanzan a reflejar toda la subjetividad capturada por las encuestas. Al no contar con esa información, se pierde parte de la información, que logramos compensar de forma parcial con marcadores indirectos como la carga asistencial, los tiempos de espera o el LWBS. Estos últimos son valiosos para describir la operación, pero su densidad informativa es menor cuando se trata de inferir percepciones.

A diferencia de los estudios contrastados, que dependen de encuestas de satisfacción aplicadas al alta hospitalaria, nuestro modelo se alimenta exclusivamente de datos ya disponibles en el registro clínico electrónico y en los sistemas administrativos del SU, es decir, reutilizamos un subproducto rutinario de la operación para extraer información valiosa sin generar carga adicional para la institución. Esto permite replicar en cualquier institución que disponga de un DAU aplicar esta metodología sin inversiones sustanciales en levantamiento primario de datos. Además de esto, este proyecto traslada el análisis hacia la Unidad hospitalaria en la que la lealtad suele descuidarse: el SU. Como ya se mencionó, el SU es, con frecuencia, la “puerta de entrada” a la red de atención y el punto donde se concentra la mayor fricción (esperas, estrés, *Boarding*, LWBS), por lo que intervenir aquí equivale a actuar en el cuello de botella que más erosiona la confianza del usuario. En otras palabras, este proyecto se diferencia del estado del arte en que captura señales tempranas

donde se afecta la lealtad en el momento exacto en que se forja la percepción institucional, usando solo información disponible de forma continua y sin costo marginal. Esta combinación de bajo costo operacional y alta relevancia estratégica, convierten a esta metodología en una alternativa particularmente valiosa para instituciones con recursos limitados y, al mismo tiempo, abre un nuevo frente de investigación sobre cómo datos operativos pueden sustituir, o complementar, mediciones subjetivas costosas cuando el objetivo es monitorear la relación del usuario y la institución de salud.

En suma, si bien nuestro trabajo comparte suficientes similitudes metodológicas con el estado del arte para establecer una comparación, difiere en tres aspectos que explican la menor AUC: el momento de medición, pues etiquetamos al egreso de urgencia y no tras días de hospitalización, la ausencia de encuestas de percepción, clave en los modelos previos; y la medición indirecta de la lealtad mediante el retorno, frente a la satisfacción capturada directamente. Paradójicamente, estas diferencias también constituyen también la fortaleza de este proyecto: al utilizar solo datos rutinarios del DAU y focalizarse en la urgencia, donde la lealtad suele descuidarse, el modelo logra señales tempranas del objeto de estudio, con costo operativo casi nulo, ofreciendo una vía sostenible en el tiempo y escalable para instituciones con recursos limitados.

7.2.- Predictores dominantes: coincidencias y contrastes con la literatura

Los estudios internacionales que examinan la satisfacción y la lealtad posteriores a la atención de urgencia son consistentes en señalar que los tiempos de espera prolongados, el LWBS y *Boarding* deterioran la experiencia del paciente de forma casi lineal, además, el perfil etario modula el efecto, observándose mayores índices de lealtad en los grupos de mayor edad. A este patrón se suma la evidencia de que el número de consultas previas, lo que denominamos Recursividad y la Hospitalización, incrementan la probabilidad de regresar al mismo prestador (16-18, 21). Nuestro modelo reproduce esos resultados: LWBS emergió como el predictor de mayor peso absoluto según los valores SHAP, seguido de cerca por la Recursividad, Hospitalización y Edad, cuya relación positiva con la lealtad se alinea

con la literatura. Esta convergencia confirma que las variables descritas en entornos internacionales también se manifiestan en los datos locales.

Una variable utilizada en este proyecto que no se presenta en la literatura es la inclusión de la cercanía geográfica al centro asistencial, obteniendo un valor SHAP que la ubica en el séptimo lugar. Su influencia sugiere que, más allá de la calidad percibida y de la eficiencia operativa, la accesibilidad espacial actúa como condicionante de la lealtad: los pacientes próximos al hospital presentan mayor propensión a regresar.

7.3.- Consideraciones éticas tanto en la medición como en el uso de la información

En la ejecución de estudios que implican la recolección y análisis de datos de pacientes, especialmente en contextos de servicios de urgencia, las consideraciones éticas ocupan un lugar primordial para garantizar la protección de los derechos y la privacidad de los individuos. Es esencial, en primer lugar, contar con la aprobación del comité de ética de la institución que provee los datos de los pacientes y reconocer la sensibilidad de la información manejada, la cual incluye datos personales y clínicos que podrían identificar directamente al paciente si no se manejan adecuadamente. Es por ello, que se realizó un proceso de anonimización de los datos meticuloso y acorde a estándares internacionales, asegurándose de que ninguna información pueda ser rastreada hasta un individuo específico. Esto incluye la eliminación de identificadores directos como nombres, números de identificación, direcciones y cualquier otro dato que pueda comprometer la confidencialidad del paciente.

Por otro lado, este proyecto hace hincapié en que la utilización de los resultados de la investigación para el desarrollo de políticas y estrategias debe guiarse por principios de justicia y equidad, asegurando que las mejoras en los servicios de salud beneficien a todos los pacientes, independientemente de su nivel económico, de lealtad o compromiso previo con la institución. Esto implica una consideración cuidadosa de cómo las intervenciones basadas en los hallazgos podrían impactar a diversos grupos de pacientes, especialmente aquellos más vulnerables o marginados. Las políticas resultantes deben buscar mejorar la experiencia y los resultados para todos los usuarios del servicio de urgencias, fomentando así

una lealtad genuina basada en el respeto, la confianza y la calidad del cuidado, en lugar de en incentivos superficiales o discriminación implícita.

En conclusión, la ética en el manejo de la información relacionada con la lealtad de los usuarios y el desarrollo posterior de políticas requiere un compromiso firme con los principios de beneficencia, no maleficencia, justicia y autonomía. Los investigadores y los formuladores de políticas deben trabajar conjuntamente para garantizar que el conocimiento generado se utilice de manera que respete la dignidad de todos los pacientes y promueva una mejora integral y equitativa en la atención de salud, reforzando así la confianza entre los usuarios y las instituciones de salud.

7.4.- Alcances del proyecto: Oportunidades para la Salud Pública Chilena

El DAU, como se ha señalado, es un registro disponible en casi todos los servicios de urgencia del país. Al sistematizar la información proveniente de él y convertirlo en una fuente de indicadores en tiempo real, no solo se obtienen beneficios para la institución en que se diseña, sino que se avanza en un modelo fácilmente replicable en otras instituciones de salud que comparten en gran medida el mismo documento, siendo así, capaces de abordar múltiples preguntas asistenciales mediante la misma metodología. De esta manera su impacto trasciende la predicción de lealtad y puede convertirse en una herramienta que contribuya en la gestión diaria de las urgencias en la red pública chilena.

En el contexto de *Overcrowding*, disponer de un DAU sistematizado abre la puerta a anticipar olas de demanda con suficiente antelación para desplegar estrategias de contención: adelantar altas médicas, reforzar turnos críticos, activar áreas de expansión o coordinar derivaciones antes de que el flujo de pacientes sobrepase la capacidad instalada. De este modo, el servicio deja de reaccionar a la saturación y pasa a prevenirla, con repercusiones directas en tiempos de espera, seguridad del paciente y calidad del cuidado.

Además de diferentes modelos predictivos, no únicamente lealtad, al sistematizar los tiempos de atención con niveles de Triage, es posible construir un tablero virtual que permita detectar

cuellos de botella, medir la efectividad de intervenciones puntuales (por ejemplo, la incorporación de un médico de clasificación en horas punta) y generar evidencia local para justificar la asignación de recursos. Cada urgencia puede así afinar sus procesos con decisiones basadas en datos, en lugar de basarse únicamente en la experiencia o la percepción subjetiva de sus equipos.

Finalmente, la sistematización del DAU facilita la comparación entre diferentes centros, identificando buenas prácticas y brechas de desempeño que hoy permanecen invisibles, maquilladas o medidas de manera inadecuada. En un sistema con recursos limitados, este conocimiento compartido constituye una oportunidad para mejorar la eficiencia global del sistema, reducir inequidades regionales y, en última instancia, elevar la calidad de la atención de urgencia en la salud pública chilena.

8.- Conclusiones

Este proyecto logra implementar un modelo predictivo con un rendimiento sólido, capaz de detectar los predictores que mejor anticipan la lealtad de los usuarios y orientar dónde focalizar los esfuerzos estratégicos, aun cuando la base de datos con que se trabajó parecía rústica y superficial. Si bien el desempeño no alcanzó la meta establecida, se obtuvo un rendimiento ligeramente menor al objetivo, con costos significativamente menores en su metodología y en un entorno de medición más relevante desde el punto de vista institucional, con resultados que pueden traducirse en herramientas prácticas para la toma de decisiones y que es potencialmente extensible a cualquier unidad que cuente con un DAU.

Sin embargo, para hacer este tipo de trabajos extensibles a toda la red pública de salud, se necesita, en primer lugar, sistemas de información con altos estándares de calidad, con el objetivo de que cada dato sea válido, completo y trazable. Además, requiere equipos clínicos capacitados, para lograr registros rigurosos y actualizados, pues la mejor plataforma fracasa si quienes la utilizan no comprenden su valor ni sus repercusiones. Y finalmente, no es posible sin el esfuerzo colectivo para la integración de información de diversas fuentes, desde laboratorios hasta sistemas de camas, para lograr así, modelos de alta capacidad. Esto exige

políticas de interoperabilidad, gobernanza de datos que garanticen consistencia sintáctica y semántica entre los diferentes repositorios y una política de colaboración entre las diferentes instituciones del país.

Cada DAU representa la historia de una persona y una familia, que acuden a la urgencia buscando alivio. Construir modelos que apoyen esta tarea no es solo un ejercicio técnico, es un compromiso ético con la salud pública. Recorrer este camino pone un ladrillo en este edificio colectivo que aspiramos a levantar: un sistema de salud guiado por la evidencia, sensible a la dignidad de cada paciente y capaz de responder con anticipación y justicia a las necesidades de la comunidad. Al integrar rigor científico con propósito social, este proyecto aporta fundamentos para que futuras iniciativas profundicen en la analítica de salud y, sobre todo, para que las decisiones clínicas y de gestión se sostengan en datos confiables al servicio de un principio simple pero ambicioso: brindar un alivio oportuno, seguro y humano a quienes confían sus vidas a la red pública chilena.

9.- Bibliografía

1. Sartini M, Carbone A, Demartini A, Giribone L, Oliva M, Spagnolo AM, et al. Overcrowding in Emergency Department: Causes, consequences, and solutions-A narrative review. *Healthcare (Basel)*. 2022;10(9):1625.
2. Departamento de Estadísticas e Información de Salud (DEIS) M de S de C (MINSAL)). Atenciones de Urgencia - Vista por Semanas Estadísticas. 2024.
3. Mix A. Pérez P. Saavedra C. Rodríguez M. Subsecretaría de redes Asistenciales MINSAL. Orientaciones Técnicas para el Rediseño al Proceso de Atención de Urgencia de Adulto, en las Unidades de Emergencia Hospitalaria. 2019 Jan.
4. Moroni A, Cendoya C, Mix A., Figueroa J., Molina P., Vera E. Estándares y Recomendaciones al Proceso de Atención de Urgencia Hospitalaria. 2018. Subsecretaría de Redes Asistenciales, Ministerio de Salud;
5. Elshove-Bolk J, Mencl F, van Rijswijck BTF, Simons MP, van Vugt AB. Validation of the Emergency Severity Index (ESI) in self-referred patients in a European emergency department. *Emergency Medicine Journal*. 2007 Mar 1;24(3):170–4.
6. Asplin BR, Magid DJ, Rhodes K V, Solberg LI, Lurie N, Camargo Jr CA. A conceptual model of emergency department crowding. *Ann Emerg Med*. 2003;42(2):173–80.
7. Crilly J, Bost N, Thalib L, Timms Jo and Gleeson H. Patients who present to the emergency department and leave without being seen: prevalence, predictors and outcomes: Prevalence, predictors and outcomes. *Eur J Emerg Med*. 2013;20(4):248–55.
8. Liu S, Nie H, Huang W, Liu X, Luo L, Lau WB, et al. Characteristics of patients who leave the emergency department without being seen: the first report in China: Patients who leave ED without being seen in China. *Emerg Med Australas*. 2014;26(3):243–8.
9. Li DR, Brennan JJ, Kreshak AA, Castillo EM, Vilke GM. Patients who leave the emergency department without being seen and their follow-up behavior: A retrospective descriptive analysis. *J Emerg Med*. 2019;57(1):106–13.
10. Johnson M, Myers S, Wineholt J, Pollack M, Kusmiesz AL. Patients who leave the emergency department without being seen. *J Emerg Nurs*. 2009;35(2):105–8.

11. Rowe BH, Channan P, Bullard M, Blitz S, Saunders LD, Rosychuk RJ, et al. Characteristics of patients who leave emergency departments without being seen. *Acad Emerg Med.* 2006;13(8):848–52.
12. Smalley CM, Meldon SW, Simon EL, Muir MR, Delgado F, Fertel BS. Emergency department patients who leave before treatment is complete. *West J Emerg Med.* 2021;22(2):148–55.
13. Laam LA, Wary AA, Strony RS, Fitzpatrick MH, Kraus CK. Quantifying the impact of patient boarding on emergency department length of stay: All admitted patients are negatively affected by boarding. *J Am Coll Emerg Physicians Open.* 2021;2(2):e12401.
14. Singer AJ, Thode Jr HC, Viccellio P, Pines JM. The association between length of emergency department boarding and mortality: Boarding and mortality. *Acad Emerg Med.* 2011;18(12):1324–9.
15. King DM, Vakkalanka JP, Junker C, Harland KK, Nugent AS. Emergency department overcrowding lowers patient satisfaction scores. *Acad Emerg Med.* 2021;28(3):363–6.
16. Kessler DP, Mylod D. Does patient satisfaction affect patient loyalty? *Int J Health Care Qual Assur.* 2011;24(4):266–73.
17. Garman AN, Garcia J, Hargreaves M. Patient satisfaction as a predictor of return-to-provider behavior: Analysis and assessment of financial implications. *Qual Manag Health Care.* 2004;13(1):75–80.
18. Meesala A, Paul J. Service quality, consumer satisfaction and loyalty in hospitals: Thinking for the future. *Journal of Retailing and Consumer Services.* 2018 Jan;40:261–9.
19. Moliner MA. Loyalty, perceived value and relationship quality in healthcare services. *J Serv Manag.* 2009;20(1):76–97.
20. Oliver RL. Whence consumer loyalty? *J Mark.* 1999;63(4_suppl1):33–44.
21. Zhou WJ, Wan QQ, Liu CY, Feng XL, Shang SM. Determinants of patient loyalty to healthcare providers: An integrative review. *Int J Qual Health Care.* 2017;29(4):442–9.

22. Lei P, Jolibert A. A three-model comparison of the relationship between quality, satisfaction and loyalty: an empirical study of the Chinese healthcare system. *BMC Health Serv Res.* 2012 Dec 30;12(1):436.
23. Amin M, Zahora Nasharuddin S. Hospital service quality and its effects on patient satisfaction and behavioural intention. *Clinical Governance: An International Journal.* 2013 Jul 19;18(3):238–54.
24. Boshoff C, Gray B. The relationships between service quality, customer satisfaction and buying intentions in the private hospital industry. *South African Journal of Business Management.* 2004 Dec 31;35(4):27–38.
25. Copago cero - Gob.cl. Gobierno de Chile.
26. ¿Cómo cubre una Isapre las prestaciones de salud cuando un cotizante tiene contratado un plan con prestador preferente? - ¿Cómo cubre una Isapre las prestaciones de salud cuando un cotizante tiene contratado un plan con prestador preferente? Preguntas Frecuentes. Superintendencia de Salud, Gobierno de Chile.
27. Fuenzalida M, Universidad Alberto Hurtado, Crespo F, Lanio I. Analysis of the geographic coverage of public hospital beds in Chile. *Rev Geogr Chile Terra Australis.* 2023;59.
28. DFL N°1 MINSAL Fija texto refundido, coordinado y sistematizado del decreto ley N° 2.763, de 1979 y de las leyes N° 18.933 y N° 18.469.. Promulgado el 23 de septiembre de 2005. Publicado en el Diario Oficial el 24/04/2006. Última versión del 14 de junio de 2021. Disponible en <https://bcn.cl/2fcqq>;
29. Historia Hospital [Internet]. Redclinica.cl. [disponible el 1 de abril de 2025]. Disponible en: <https://www.redclinica.cl/institucional/historia-hospital.aspx>.
30. Geron A. Hands-on machine learning with scikit-learn, keras, and TensorFlow 3e: Concepts, tools, and techniques to build intelligent systems. 3rd ed. Sebastopol, CA, Estados Unidos de América: O'Reilly Media; 2022.
31. Fortino A. Data mining and predictive analytics for business decisions: A case study approach. Dulles Town Center, VA, Estados Unidos de América: Mercury Learning & Information; 2023.
32. Pigott TD. A Review of Methods for Missing Data. *Educational Research and Evaluation.* 2001 Dec 9;7(4):353–83.

33. Singh D, Singh B. Investigating the impact of data normalization on classification performance. *Appl Soft Comput.* 2020 Dec;97:105524.
34. Boukerche A, Zheng L, Alfandi O. Outlier Detection. *ACM Comput Surv.* 2021 May 31;53(3):1–37.
35. Remeseiro B, Bolon-Canedo V. A review of feature selection methods in medical applications. *Comput Biol Med.* 2019 Sep;112:103375.
36. Kuhn M, Johnson K. Feature engineering and selection: A practical approach for predictive models. Filadelfia, PA, Estados Unidos de América: Chapman & Hall/CRC; 2019.
37. Bishop C. Pattern Recognition and Machine Learning. 1st ed. Nueva York, NY, Estados Unidos de América: Springer; 2006.
38. Fratello M, Tagliaferri R. Decision Trees and Random Forests. In: *Encyclopedia of Bioinformatics and Computational Biology*. Elsevier; 2019. p. 374–83.
39. Chen T, Guestrin C. XGBoost. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: ACM; 2016. p. 785–94.
40. Zou H, Hastie T. Regularization and Variable Selection Via the Elastic Net. *J R Stat Soc Series B Stat Methodol.* 2005 Apr 1;67(2):301–20.
41. Zhou ZH. Machine Learning. Singapore: Springer Singapore; 2021.
42. Schrage M, Kiron D. Leading with next-generation key performance indicators. Massachusetts Institute of Technology; 2018.
43. Kaggle: Your machine learning and data science community. [Kaggle.com](https://www.kaggle.com).
44. Machado MR, Karray S, de Sousa IT. LightGBM: An effective decision tree gradient boosting method to predict customer loyalty in the finance industry. In: *2019 14th International Conference on Computer Science & Education (ICCSE)*. IEEE; 2019.
45. Surya PSS, Anitha K. Comparative analysis of accuracy and prediction of customer loyalty in the telecom industry using novel diverse algorithm. In: *2022 International Conference on Business Analytics for Technology and Security (ICBATS)*. IEEE; 2022.
46. Lalwani P, Mishra MK, Chadha JS, Sethi P. Customer churn prediction system: a machine learning approach. *Computing.* 2022;104(2):271–94.

47. Youngkeun Choi JWC. The Prediction of Hotel Customer Loyalty using Machine Learning Technique. *International Journal of Advanced Trends in Computer Science and Engineering*. 2020 Oct 15;9(5):7908–15.
48. Simsekler MCE, Alhashmi NH, Azar E, King N, Luqman RAMA, Al Mulla A. Exploring drivers of patient satisfaction using a random forest algorithm. *BMC Med Inform Decis Mak*. 2021 Dec 13;21(1):157.
49. Bari V, Hirsch JS, Narvaez J, Sardinia R, Bock KR, Oppenheim MI, et al. An approach to predicting patient experience through machine learning and social network analysis. *Journal of the American Medical Informatics Association*. 2020 Dec 9;27(12):1834–43.
50. Liu N, Kumara S, Reich E. Gaining Insights Into Patient Satisfaction Through Interpretable Machine Learning. *IEEE J Biomed Health Inform*. 2021 Jun;25(6):2215–26.
51. Galatas G, Zikos D, Makedon F. Application of data mining techniques to determine patient satisfaction. In: *Proceedings of the 6th International Conference on Pervasive Technologies Related to Assistive Environments*. New York, NY, USA: ACM; 2013.
52. HIPAA - computer & information security - information resources & technology (IRT) - Stanford university school of medicine. *Technology & Digital Solutions*.
53. Lundberg S, Lee SI. A Unified Approach to Interpreting Model Predictions. 2017 May 22;
54. Morley C, Unwin M, Peterson GM, Stankovich J, Kinsman L. Emergency department crowding: A systematic review of causes, consequences and solutions. *PLoS One*. 2018 Aug 30;13(8):e0203316.
55. Sanchez M, Smally AJ, Grant RJ, Jacobs LM. Effects of a fast-track area on emergency department performance. *J Emerg Med*. 2006 Jul;31(1):117–20.
56. Devkaran S, Parsons H, Van Dyke M, Drennan J, Rajah J. The impact of a fast track area on quality and effectiveness outcomes: A Middle Eastern emergency department perspective. *BMC Emerg Med*. 2009 Dec 17;9(1):11.
57. Ehrler F, Rochat J, Siebert JN, Guessous I, Lovis C, Spechbach H. Use of a Semiautomatic Text Message System to Improve Satisfaction With Wait Time in the

Adult Emergency Department: Cross-sectional Survey Study. JMIR Med Inform. 2022 Sep 6;10(9):e34488.

58. MINSAL. LEY 21.621. FORTALECE EL VÍNCULO ENTRE EL HOSPITAL CLÍNICO DE LA UNIVERSIDAD DE CHILE ``DR. JOSÉ JOAQUÍN AGUIRRE`` Y EL SISTEMA NACIONAL DE SERVICIOS DE SALUD. 2023.
59. Paciente Convenio - Ley N° 21.621. Redclinica.cl. Disponible en https://www.redclinica.cl/institucional/paciente_convenio_ley_21621.aspx

ANEXOS

ANEXO 1. Variables Demográficas obtenidas a partir de la atención en SU.

Categorías	Variables DAU	Observaciones
Demográficas	ID	ID de paciente
	EDAD	Edad de paciente
	GENERO	Genero de paciente
	PREVISION	Previsión de paciente
	COMUNA	Comuna de residencia de paciente
	NACIONALIDAD	Nacionalidad de paciente

ANEXO 2. Variables Clínicas obtenidas a partir de la atención en SU.

Categorías	Variables DAU	Observaciones
Clínicas	MEDIO	Medio de llegada: Por sus propios medios, Ambulancia
	TRIAGE	Resultado de TRIAGE
	MOTIVO_URGENCIA	Texto libre de motivo de consulta
	TEMP	Temperatura de paciente en categorización
	PA	Presión arterial de paciente en categorización
	FC	Frecuencia cardiaca de paciente en categorización
	EVA	Escala de dolor EVA de paciente en categorización
	CIE_10	Diagnóstico CIE_10
	DIAGNOSTICO	Diagnóstico en texto libre
	MOT_ALTA	Estado del paciente al final del evento: Mejorado, No mejorado, Estabilizado, Alta exigida, Otro motivo de alta, Traslado a otro centro
	DESTINO	Destino luego del evento: Hospitalización, Domicilio, Otro, Traslado

ANEXO 3. Variables Administrativas obtenidas a partir de la atención en SU.

Categorías	Variables DAU	Observaciones
Administrativas	FECHA_INGRESO	Fecha y hora de admisión a urgencia
	FECHA_TRIAGE	Fecha y hora de realización de TRIAGE
	FECHA_PRIMERA_CONSULTA	Fecha y hora de primera consulta médica
	FECHA_ALTA_MEDICA	Fecha y hora de alta médica
	FECHA_EGRESO	Fecha y hora de cierre de evento
	ING_HOSP	Fecha ingreso hospitalización
	EGR_HOSP	Fecha egreso de hospitalización
	BOX	Box de urgencia en el que se realizó la atención
	SERVICIO	Servicio donde se hospitaliza
	MEDICO_RESPONSABLE	Médico responsable de hacer el Alta médica

ANEXO 4. Presencia de valores faltantes y atípicos en Variables Demográficas, junto con su manejo en caso de que corresponda.

Variable	Tipo de Variable	Observaciones	Manejo
EDAD	Continua / Entero	0 NaN (0%)	Sin NaN ni valores Outlier
GENERO	Catagórica / Binaria	0 NaN (0%)	Sin NaN ni valores Outlier
COMUNA	Catagórica de Alta Cardinalidad	2055 NaN (1.46%)	Se crearon agrupaciones de comunas para identificar al usuario, siendo cada agrupación una variable. En el caso de que no tenga comuna asociada, tendrá valor 0 en cada una de las variables.
PREVISION	Catagórica de Alta Cardinalidad	20 NaN (0.01%)	Se crearon agrupaciones de previsión. En caso de no tener previsión tendrá valor 0 en cada una de las variables.
NACIONALIDAD	Catagórica de Alta Cardinalidad	2086 NaN (1.49%)	A partir de nacionalidad se creo la variable "Chileno", cuyo valor es = 1 cuando Nacionalidad = Chileno, siendo 0 en todo el resto de los casos, incluyendo NaN.

ANEXO 5. Presencia de valores faltantes y atípicos en Variables Clínicas, junto con su manejo en caso de que corresponda.

Variable	Tipo de Variable	Total NaN	Manejo
TRIAGE	Catégorica: Ordinalidad de 5	827 NaN (0.59%)	Se crea una variable por cada categoría, resultando valor 0 en todas las variables en el caso de los pacientes que no se realizaron Triage.
TEMPERATURA	Continua	7551 NaN (5.38%)	Se crea variable "Fiebre" igual a 1 si Temperatura es mayor a 37.7, todo el resto de los casos, incluido NaN, son 0
PRESION	Continua	0 NaN (0%)	Sin NaN ni valores Outlier
FC	Continua	3735 NaN (2.66%)	Se crea variable "Taquicardia" igual a 1 si FC es mayor a 99 todo el resto de los casos, incluido NaN, son 0
EVA	Continua / Entero	22202 NaN (15.82%)	Se crea variable "Dolor" igual a 1 si EVA es mayor a 99 todo el resto de los casos, incluido NaN, son 0
MEDIO DE LLEGADA	Catégorica de baja cardinalidad	446 NaN (0.32%)	Se elimina la variable, debido a que todos los pacientes presentan el mismo modod de llegada, por lo que no representa la realidad.
COD_DIAG	Continua	17 NaN (0.01%)	Se utiliza esta variable para verificar pacientes que rechazan atención o se van sin ser atendidos, posteriormente se elimina fila.
DIAGNOSTICO	Continua / Entero	17 NaN (0.01%)	Se utiliza esta variable para verificar pacientes fallecidos, posteriormente se elimina fila.
MOT_ALTA	Catégorica de Baja Cardinalidad	1 NaN (0%)	Se utiliza esta variable para verificar pacientes fallecidos, posteriormente se elimina fila.
DESTINO	Catégorica de Baja Cardinalidad	446 NaN (0.32%)	Se crea una variable por cada Destino posible, en caso de que sea NaN, se observará el Motivo de Alta. Si este es "Mejorado", o "Estabilizado", Destino será = a domicilio, en todos los otros casos su destino será "OTROS"
MOTIVO_TRIAGE	Lenguaje Natural	880 NaN (0.63%)	Se elimina la variable a causa de que este proyecto no realiza procesamiento de lenguaje natural.
HOSPITALIZADO	Binaria	0 NaN (0%)	Sin NaN ni valores Outlier

ANEXO 6. Presencia de valores faltantes y atípicos en Variables Administrativas, junto con su manejo en caso de que corresponda.

Variable	Tipo de Variable	Observaciones	Manejo
FECHA_INGRESO	Formato Datetime	0 NaN (0%)	Sin NaN ni valores Outlier
FECHA_EGRESO	Formato Datetime	57 NaN (0.04%)	Alta coincidencia con FECHA.ALTA.MÉDICA, presentando además, un 9.6% de Outliers, evidenciando que en el proceso clínico se dan de alta los pacientes, pero en un porcentaje importante no se quita al paciente del sistema.
FECHA.ALTA.MEDICA	Formato Datetime	0 NaN (0%)	Sin NaN ni valores Outlier
FECHA.PRIMERA.CON SULTA	Formato Datetime	18495 NaN (13.18%)	Coincide plenamente con los pacientes que abandonan el Servicio de Urgencia sin atención médica. En conjunto con la variable COD.DIAG crean la variable "999" que hace alusión a estos pacientes.
FECHA.TRIAGE	Formato Datetime	827 NaN (0.59%)	Coincide plenamente con los pacientes que abandonan el Servicio de Urgencia sin atención médica, pero en estos casos abandonan incluso previo a Triage. En conjunto con la variable COD.DIAG crean la variable "999" que hace alusión a estos pacientes.
FECHA.TRASLADO	Formato Datetime	119329 NaN (85.02%)	Es la Fecha en que se traslada a sala, por lo que coincide con los usuarios que fueron hospitalizados.
MEDICO.RESPONSAB LE	Catógórica de Alta Cardinalidad	1 NaN (0%)	Se utiliza la variable para el cálculo del total de médicos por turno. Posteriormente se elimina.
BOX	Catógórica de Alta Cardinalidad	26132 NaN (18.62%)	Se elimina la variable.
SERVICIO	Catógórica de Alta Cardinalidad	119329 NaN (85.02%)	Indica el Servicio en que el paciente se hospitalizó. NaN en todos los pacientes que no hubo hospitalización. Se creará la variable SERV.LOY que será = 1 para los pacientes hospitalizados en los Servicios que presentan mayor porcentaje de pacientes con Loyal = 1

ANEXO 7. Variables Demográficas. Análisis descriptivo y estadístico univariado.

Variable	Tipo de Variable	Observaciones	Relación con Lealtad	Gráfico
EDAD	Continua / Entero	Edad media 46 años, Media leal = 1: 47.95 Media leal = 0: 43.55 años Prueba normalidad (-)	U-Test: 1.8×10^{-8} p-value <0.05 Coef Corr: 0.10 Asociación débil pero estadísticamente significativa	
GENERO	Catégorica / Binaria	55.89% de las atenciones son a mujeres.	χ^2 : 69.64 p-value <0.05 ϕ : 0.022 Asociación muy débil pero estadísticamente significativa	
COMUNA	Catégorica de Alta Cardinalidad	263 comunas diferentes de Chile, con 0,01% de NaN, correspondiente en su mayoría a extranjeros.		
COM_RM	Binaria / Generada a partir de COMUNA	Reúne las comunas de la RM. Recoge el 95% de las atenciones	Existe asociación muy débil, casi inexistente entre las variables relativas a previsión y lealtad, pero la diferencia es estadísticamente significativa.	
COM_STGO	Binaria / Generada a partir de COMUNA	Variable binaria correspondiente únicamente a la comuna de Santiago, corresponde al 6,9% de las atenciones.		
COM_NORTE	Binaria / Generada a partir de COMUNA	Reúne las comunas del sector norte de la RM, más cercana geográficamente al HCUCH. Recogiendo el 45% de las consultas.		
COM_ABCI	Binaria / Generada a partir de COMUNA	Reúne las comunas del sector oriente de la RM, con mayor poder adquisitivo, que podrían tener un comportamiento similar. Responde al 1,3% de las consultas		
PREVISION	Catégorica de Alta Cardinalidad	132 valores diferentes, dado que diferentes subtipos de cada Previsión se expresaba en el set de datos. 0,0001% de NaN		
ISAPRE_GRAL	Binaria / Generada a partir de PREVISION	Reúne a aquellos pacientes con asegurados privadas, pero sin convenio preferente con el HCUCH. 19,39%	Existe asociación muy débil, casi inexistente entre las variables relativas a previsión y lealtad, pero la diferencia es estadísticamente significativa.	
ISAPRE_PREFERENTE	Binaria / Generada a partir de PREVISION	Reúne a aquellos pacientes con aseguradoras privadas que tengan convenio preferente con HCUCH. 26,35% de las atenciones.		
CAEC	Binaria / Generada a partir de PREVISION	Reúne a aquellos pacientes con aseguradoras privadas que tengan convenio preferente con HCUCH. 25,9% de las atenciones.		
UCHILE	Binaria / Generada a partir de PREVISION	Vinculación a la Universidad de Chile. 3% de las consultas,		
GES	Binaria / Generada a partir de PREVISION	Al ingreso con sospecha de patología GES consignada en PREVISION. 0,58%		
FONASA	Binaria / Generada a partir de PREVISION	Reúne a aquellos pacientes con Previsión FONASA LIBRE ELECCIÓN		
PARTICULAR	Binaria / Generada a partir de PREVISION	Pacientes que se atendieron de manera particular o FONASA A. 3,73% de las atenciones.		
NACIONALIDAD	Catégorica de Alta Cardinalidad	36 valores distintos. 0,14% de NaN		
CHILENO	Binaria / Generada a partir de NACIONALIDAD	Reúne a paciente de Nacionalidad Chilena. Corresponde al 97,6%	χ^2 : 179.94 p-value <0.05 ϕ : 0.035 Asociación muy débil pero estadísticamente significativa	

ANEXO 8. Variables Clínicas. Análisis descriptivo y estadístico univariado.


Variable	Tipo de Variable	Observaciones	Relación con Lealtad	Gráfico																								
TRIAGE	Catégorica: Ordinalidad de 5	Categorización de gravedad de cada paciente. NaN = 0,005%. 98,5% de las consultas corresponden a TRIAGE II, III y IV	Existe asociación muy débil entre cada Triage y lealtad, pero la diferencia es estadísticamente significativa. TRIAGE II y V son los que presentan mayor asociación. <table><tr><th>TRIAGE</th><th>χ²</th><th>p-value</th><th>φ</th></tr><tr><td>I</td><td>12.5</td><td><0.05</td><td>-0.01</td></tr><tr><td>II</td><td>724.12</td><td><0.05</td><td>0.07</td></tr><tr><td>III</td><td>71.56</td><td><0.05</td><td>-0.02</td></tr><tr><td>IV</td><td>51.00</td><td><0.05</td><td>-0.02</td></tr><tr><td>V</td><td>606.59</td><td><0.05</td><td>-0.07</td></tr></table>	TRIAGE	χ²	p-value	φ	I	12.5	<0.05	-0.01	II	724.12	<0.05	0.07	III	71.56	<0.05	-0.02	IV	51.00	<0.05	-0.02	V	606.59	<0.05	-0.07	
TRIAGE	χ²	p-value	φ																									
I	12.5	<0.05	-0.01																									
II	724.12	<0.05	0.07																									
III	71.56	<0.05	-0.02																									
IV	51.00	<0.05	-0.02																									
V	606.59	<0.05	-0.07																									
FIEBRE	Binaria	Generada a partir de signos vitales. T° >37.8	Existe asociación muy débil, casi inexistente entre las variables relativas a Signos vitales y lealtad, pero la diferencia es estadísticamente significativa. <table><tr><th>SV</th><th>χ²</th><th>p-value</th><th>φ</th></tr><tr><td>FIEBRE</td><td>5.76</td><td><0.05</td><td>0.006</td></tr><tr><td>HIPOTENSO</td><td>42.3</td><td><0.05</td><td>0.017</td></tr><tr><td>HIPERTENSO</td><td>165.9</td><td><0.05</td><td>0.034</td></tr><tr><td>TAQUICARDIA</td><td>20.6</td><td><0.05</td><td>0.012</td></tr><tr><td>DOLOR</td><td>70.9</td><td><0.05</td><td>0.023</td></tr></table>	SV	χ²	p-value	φ	FIEBRE	5.76	<0.05	0.006	HIPOTENSO	42.3	<0.05	0.017	HIPERTENSO	165.9	<0.05	0.034	TAQUICARDIA	20.6	<0.05	0.012	DOLOR	70.9	<0.05	0.023	
SV	χ²	p-value		φ																								
FIEBRE	5.76	<0.05		0.006																								
HIPOTENSO	42.3	<0.05		0.017																								
HIPERTENSO	165.9	<0.05		0.034																								
TAQUICARDIA	20.6	<0.05	0.012																									
DOLOR	70.9	<0.05	0.023																									
HIPOTENSO	Binaria	Generada a partir de signos vitales. Si Presión Arterial en Triage es < 90/60mmHg																										
HIPERTENSO	Binaria	Generada a partir de signos vitales. Si Presión Arterial en Triage es < 150/110mmHg																										
TAQUICARDIA	Binaria	Generada a partir de signos vitales. Si Frecuencia Cardíaca en Triage es > 120lpm																										
DOLOR	Binaria	Generada a partir de Autoevaluación de nivel de dolor por parte del paciente según Escala Visual Análoga (EVA) > 7/10																										
SV_ALT	Binaria / Generada a partir de los SV	Busca mayor sensibilidad que el Triage. Es igual a 1 si PAD <60, PAS >140, T° > 37.8 FC >100 o EVA > 6	Al generar una variable binaria que informe alteración de los signos vitales tampoco se obtiene una asociación fuerte. Aún es una relación muy débil casi inexistente. <table><tr><th>SV</th><th>χ²</th><th>p-value</th><th>φ</th></tr><tr><td>SV_ALT</td><td>294.9</td><td><0.05</td><td>0.046</td></tr></table>	SV	χ²	p-value	φ	SV_ALT	294.9	<0.05	0.046																	
SV	χ²	p-value	φ																									
SV_ALT	294.9	<0.05	0.046																									
SUMA.SV	Continua: Ordinalidad 5	Número de Signos vitales alterados	U-Test: 2.2x10¹⁰ p-value <0.05 Coef Corr: 0.047 Asociación débil pero estadísticamente significativa																									
999	Binaria / Generada a partir de COD_DIAG	Aquellos códigos diagnósticos que parten con 999 indican que la consulta no se llevó a cabo porque el paciente se fue sin ser atendido. Corresponde a LWBS	χ²: 18835 p-value <0.05 φ : 0.37 Asociación moderada y diferencia estadísticamente significativa																									
FALLECE	Binaria / Generada a partir de DIAGNOSTICO	Se realiza búsqueda por palabras dentro de DIAGNÓSTICO. 133 pacientes que fallecen en SU. No se tiene información de pacientes post SU																										
DESTINO	Catégorica	Diferentes destinos de los pacientes luego de la atención de urgencia. Divididos en Hospitalizados, Alta a domicilio y Otros																										
HOSP	Binaria / Generada a partir de Destino	Pacientes que luego de atención de urgencia se procede a hospitalizar	Existe asociación débil a moderada entre las variables relativas al Destino del paciente con diferencia es estadísticamente significativa. <table><tr><th>DESTINO</th><th>χ²</th><th>p-value</th><th>φ</th></tr><tr><td>HOSP</td><td>6240</td><td><0.05</td><td>0.21</td></tr><tr><td>ALTA_DOM</td><td>2079</td><td><0.05</td><td>0.12</td></tr><tr><td>OTRO.DEST</td><td>16399</td><td><0.05</td><td>0.34</td></tr></table>	DESTINO	χ²	p-value	φ	HOSP	6240	<0.05	0.21	ALTA_DOM	2079	<0.05	0.12	OTRO.DEST	16399	<0.05	0.34									
DESTINO	χ²	p-value		φ																								
HOSP	6240	<0.05		0.21																								
ALTA_DOM	2079	<0.05	0.12																									
OTRO.DEST	16399	<0.05	0.34																									
ALTA_DOM	Binaria / Generada a partir de Destino	Pacientes que luego de la atención de urgencia se indica alta médica																										
OTRO_DESTINO	Binaria / Generada a partir de Destino	Pacientes que no se da alta médica ni hospitalización. Incluye traslado a otros centros, rechazo de hospitalización entre otros.																										

ANEXO 9. Variables Administrativas. Análisis descriptivo y estadístico univariado.

Variable	Tipo de Variable	Observaciones	Relación con Lealtad	Gráfico
N.PAX	Continua / Entero	Generada a partir de las fechas de ingreso y egreso de los pacientes. Indica cuántos pacientes hay en el SU al momento del ingreso. Media leal = 1: 15.2 pacientes Media leal = 0: 16.8 pacientes	U-Test: 2.4×10^{-9} p-value <0.05 Coef Corr: -0.1 Asociación débil pero con diferencia estadísticamente significativa	
Tiempo.1	Continua / Minutos	Tiempo en minutos desde Ingreso a Triage. Media leal = 1: 9.7 minutos Media leal = 0: 10.2 minutos	Existe asociación débil y casi inexistente entre las variables relativas al tiempo del proceso, destacando el tiempo del proceso completo de Urgencia.	
Tiempo.2	Continua / Minutos	Tiempo en minutos desde Triage a Primera Atención Médica Media leal = 1: 59 minutos Media leal = 0: 69 minutos		
Tiempo.SU	Continua / Hrs	Tiempo en horas de todo el proceso de Urgencia Media leal = 1: 4.1 hrs Media leal = 0: 3.4 hrs		
N.PAX.OUT	Continua / Generada	Número de pacientes que esperan atención médica cuando el paciente se admite.	Existe asociación débil entre las variables relativas al número de pacientes en el SU, con diferencia estadísticamente significativa.	
N.PAX.IN	Continua / Generada	Número de pacientes que ya recibieron primera atención médica y aún no han sido dados de alta.		
N.MEDS	Continua / Generada	Generada a partir MEDICO.RESPONSABLE. Número de médicos disponibles el turno en que fue admitido el paciente.	U-Test: 2.2×10^{-9} p-value <0.05 Coef Corr: -0.02 Asociación muy débil o inexistente pero con diferencia estadísticamente significativa.	
DIA.SEM	Categorica / Generada	Día de la semana en la que se lleva a cabo la atención.	Existe asociación prácticamente inexistente entre los días de la semana y lealtad.	
RECURSIVIDAD	Continua / Entero	Número de veces que, en el tiempo observado, el paciente ha sido atendido hasta esa fecha	U-Test: 2.8×10^{-9} p-value <0.05 Coef Corr: 0.06 Asociación débil con diferencia estadísticamente significativa.	
DIAS.HOSP	Continua / Entero	Número de días hospitalizado Media leal = 1: 7.74 días Media leal = 0: 7.22 días	U-Test: 1.5×10^{-7} p-value <0.05 Coef Corr: 0.05 Asociación muy débil pero con diferencia estadísticamente significativa	
T.TRASLADO	Continua / Generada a partir de la fecha de hospitalización	Generada a partir de la diferencia entre tiempo de alta e ingreso a Hospitalización Media leal = 1: 3.84 hrs Media leal = 0: 5.12 hrs	U-Test: 1.9×10^{-7} p-value <0.05 Coef Corr: -0.05 Asociación muy débil pero con diferencia estadísticamente significativa	

ANEXO 10. Matriz de Correlación entre variables predictoras

Matriz de correlación entre variables predictoras



ANEXO 11. Hiperparámetros utilizados para cada modelo, definición e interpretación.

Modelo	Hiperparámetro	Interpretación técnica y rol en el modelo
XGBoost	n_estimators	Número total de árboles a entrenar. Un número mayor permite capturar relaciones complejas, pero incrementa el riesgo de sobreajuste si no se regula.
	max_depth	Profundidad máxima de cada árbol. Controla la complejidad del modelo; árboles más profundos pueden aprender interacciones no lineales, pero también sobreajustar.
	learning_rate	Tasa de aprendizaje del boosting. Cuanto menor, más lento y fino es el aprendizaje; requiere más árboles pero mejora la generalización.
	subsample	Fracción de muestras usadas para construir cada árbol. Introduce aleatoriedad, ayuda a evitar sobreajuste y mejora robustez.
	colsample_bytree	Proporción de características utilizadas al construir cada árbol. Reduce la correlación entre árboles, promoviendo diversidad del ensamble.
	gamma	Umbral mínimo de ganancia para dividir un nodo. Aumentarlo fuerza al modelo a dividir solo cuando hay ganancia clara, actuando como regularizador.
	min_child_weight	Número mínimo de instancias por hoja. Valores más altos previenen divisiones muy específicas, reduciendo sobreajuste en muestras pequeñas.
LightGBM	n_estimators	Igual que en XGBoost. Determina cuántos árboles serán agregados secuencialmente.
	num_leaves	Número máximo de hojas por árbol. Controla la capacidad de los árboles en LightGBM (que crecen hoja a hoja). Demasiadas hojas pueden sobreajustar.
	max_depth	Límite para la profundidad del árbol. Protege contra estructuras excesivamente complejas.
	learning_rate	Similar a XGBoost. Reduce el impacto de cada nuevo árbol, obligando al modelo a aprender más lentamente pero con mayor precisión.
	subsample	Igual que en XGBoost. Ayuda a evitar sobreajuste al entrenar con solo una fracción aleatoria del conjunto de entrenamiento.
	colsample_bytree	También igual que en XGBoost. Selección aleatoria de características en cada árbol mejora la generalización.
	lambda_1 / lambda_2	Coefficientes de regularización L1 y L2. Penalizan valores grandes en los parámetros del modelo, mejorando la capacidad de generalización.
Random Forest	n_estimators	Número total de árboles independientes. Más árboles reducen la varianza, pero aumentan el tiempo de cómputo.
	max_depth	Profundidad máxima permitida por árbol. Protege contra árboles demasiado específicos que memoricen los datos.
	max_features	Número o proporción de características evaluadas en cada división. Menores valores fomentan diversidad entre árboles y evitan sobreajuste.
	min_samples_split	Número mínimo de muestras requerido para dividir un nodo. Aumentarlo restringe la formación de ramas pequeñas.
	min_samples_leaf	Mínimo de muestras por hoja terminal. Obliga al modelo a formar hojas más grandes, lo que suaviza las predicciones.
	bootstrap	Si los árboles deben entrenarse sobre una muestra aleatoria con reemplazo. Desactivar puede reducir la varianza pero aumenta riesgo de sobreajuste.
Regresión Logística (L2)	C	Inverso de la fuerza de regularización L2. Valores bajos (p. ej. 0.01) penalizan coeficientes grandes, evitando modelos sobreajustados.
Regresión Logística (Elastic Net)	C	Igual que en L2. Controla cuánto se permite que los coeficientes crezcan.
	l1_ratio	Proporción entre regularización L1 y L2. L1 induce esparsidad (selección de variables), L2 estabiliza el modelo. Permite balancear ambos efectos.
Red Neuronal (MLP)	hidden_layer_sizes	Estructura y número de capas ocultas. Define la capacidad de la red para capturar relaciones complejas y no lineales.
	activation	Función de activación no lineal. relu es eficiente y dominante; tanh puede ser útil si los datos están centrados.
	alpha	Término de regularización L2 (decay). Penaliza pesos grandes en la red, reduciendo el riesgo de sobreajuste.
	learning_rate_init	Valor inicial de la tasa de aprendizaje. Controla el tamaño de los pasos durante la optimización. Tasas bajas ofrecen más estabilidad.
	batch_size	Tamaño de los mini-lotes para el entrenamiento. Tamaños más grandes estabilizan el gradiente, pero pueden hacer que el modelo tarde más en converger.

ANEXO 12. Hiperparámetros óptimos ajustados para cada modelo entrenado.

Modelo	Hiperparámetros óptimos
XGBoost	n_estimators=400, max_depth=5, learning_rate=0.02, subsample=0.5, colsample_bytree=0.7, eval_metric='logloss', random_state=42
LightGBM	n_estimators=500, num_leaves=11, learning_rate=0.02, subsample=0.5, colsample_bytree=0.7, random_state=42
RandomForest	n_estimators=300, max_depth=15, min_samples_split=4, min_samples_leaf=4, max_features='log2', bootstrap=True, n_jobs=-1, random_state=42
LogisticL2	C=11.288, penalty='l2', solver='lbfgs', max_iter=10000, random_state=42
LogisticEN	C=1.624, l1_ratio=0.7, penalty='elasticnet', solver='saga', max_iter=10000, random_state=42
NeuralNet	hidden_layer_sizes=(100,), alpha=0.1, learning_rate_init=0.0002, max_iter=300, random_state=42, preprocesamiento: StandardScaler