



Escuela de Posgrados

Construcción de un modelo predictivo para determinar el tiempo de intervenciones quirúrgicas en un Hospital Público de Medellín

German Darío Pulgarín Rojas
Diego Alexander Barrero Londoño

Asesor: PhD. Juan Sebastián Parra Sánchez

Especialización en Big Data e Inteligencia de Negocios
Facultad de ingeniería y Arquitectura
Universidad Católica Luis Amigo
Medellín, Colombia
2023

Dedicatoria

Queremos dedicar este trabajo de grado a nuestros queridos padres, familiares y personas cercanas que han sido testigos de nuestro proceso y han brindado un apoyo incondicional en cada paso que hemos dado.

A nuestros padres, quienes conocen de cerca los obstáculos y adversidades que hemos enfrentado durante esta travesía, les agradecemos de corazón por su constante aliento, comprensión y por ser nuestro soporte inquebrantable. Su amor incondicional y su confianza en nuestras capacidades nos han dado la fuerza necesaria para superar cualquier desafío.

A nuestras parejas y amigos cercanos, quienes han sido fuente de inspiración, motivación y aliento constante, les agradecemos por creer en nosotros, por comprender nuestras dedicaciones y por ser nuestro sostén emocional en los momentos más exigentes.

Este trabajo de grado no habría sido posible sin el respaldo y la confianza que ustedes nos han brindado. Cada logro obtenido es también suyo, y estamos profundamente agradecidos por ser parte de nuestras vidas y por ser testigos de nuestro crecimiento académico y personal.

Agradecimientos

Expresamos nuestro agradecimiento especial al personal del hospital en el cual gestamos este proyecto, por abrirnos las puertas y proporcionarnos la valiosa información necesaria para llevar a cabo esta investigación. Su colaboración y disposición para compartir datos y conocimientos fueron fundamentales para el desarrollo exitoso de nuestro modelo predictivo.

Resumen

La planificación del uso de quirófanos en los sistemas de atención médica ha dependido históricamente de métodos empíricos debido a la falta de conocimiento sobre el tiempo estimado de las cirugías. En este contexto, el presente trabajo tuvo como objetivo principal desarrollar un modelo predictivo para calcular el tiempo de duración de las cirugías en un Hospital Público de Medellín.

Se implementó un modelo supervisado de Machine Learning en diferentes escenarios, incluyendo cirugías generales, especializadas en ortopedia y el conjunto global de las 29 especialidades médicas existentes en el estudio. El propósito fue evaluar la capacidad predictiva del modelo en condiciones variables. Bajo la metodología CRISP-DM los resultados obtenidos demuestran que el modelo tuvo una capacidad predictiva superior al 88% de rendimiento, con un desfase máximo de 25 minutos.

En este estudio los resultados generados respaldan la aplicación de enfoques predictivos basados en modelos supervisados, destacando el potencial y la relevancia del Machine Learning en el ámbito hospitalario, especialmente en la predicción de tiempos quirúrgicos.

Palabras clave: tiempos de cirugías, Machine Learning, quirófanos, modelo supervisado, CRISP-DM.

Contenido

1. Introducción	8
2. Planteamiento del Problema	9
3. Justificación	11
4. Marco de Referencia	13
5. Antecedentes	15
6. Objetivos	18
6.1. Objetivo General	18
6.2. Objetivos Específicos	18
7. Viabilidad	19
8. Metodología	20
Fase I. Entendimiento del negocio	20
Fase II. Entendimiento de los datos	21
Fase III. Preparación de los datos	21
Fase IV. Modelado	22
Fase V. Evaluación	23
Fase VI. Despliegue	23
9. Resultados	24
9.1. Entendimiento de los datos	24
9.2. Preparación de los datos	28
9.3. Modelado	30
9.4. Evaluación	31
9.4.1 Escenarios categoría de cirugía general	32
9.4.2 Categoría de cirugía ortopedia	33
9.4.3 Todo el conjunto de datos	35
9.5. Despliegue	36
10. Conclusiones	37
11. Recomendaciones	38
12. Referencias	39

Lista de Figuras

<i>Figura 1. Diagrama de la metodología CRISP-DM</i>	20
<i>Figura 2. muestra simple del modelo predictivo de regresión lineal</i>	23
<i>Figura 3. Categorías de cirugías</i>	24
<i>Figura 4. Tiempo de duración promedio por cirugía</i>	25
<i>Figura 5. Género.</i>	25
<i>Figura 6. Promedio edad</i>	26
<i>Figura 7. Estatus de cirugía</i>	26
<i>Figura 8. Nivel de complejidad.</i>	27
<i>Figura 9. Personal activo en quirófano.</i>	27
<i>Figura 10. Promedio personal médico según complejidad.</i>	28
<i>Figura 11. Columnas contenidas en el archivo insumo y su tipo.</i>	28
<i>Figura 12. Columnas finales elegidas para entrenar el modelo.</i>	29
<i>Figura 13. Matriz de correlaciones</i>	30
<i>Figura 14. Archivos binarios generados de los modelos</i>	36

Lista de tablas

<i>Tabla 1. Fórmulas de las métricas de evaluación del modelo.</i>	31
<i>Tabla 2. Coeficientes resultados del modelo categoría de cirugía general.</i>	32
<i>Tabla 3. Métricas resultado del modelo categoría de cirugía general.</i>	33
<i>Tabla 4. Coeficientes resultados del modelo categoría de cirugía ortopedia.</i>	33
<i>Tabla 5. Métricas resultado del modelo categoría de cirugía ortopedia.</i>	34
<i>Tabla 6. Coeficientes resultados del modelo de todos los datos.</i>	35
<i>Tabla 7. Métricas resultado del modelo de todos los datos.</i>	36

1. Introducción

Un Hospital Público de Medellín se enfrenta a un desafío importante relacionado con la predicción del tiempo promedio de duración de las cirugías, considerando la diversidad de procedimientos quirúrgicos que ofrece y la disponibilidad de quirófanos. Con el objetivo de abordar esta problemática, se propuso desarrollar un modelo predictivo basado en regresión lineal multivariable que permite pronosticar con mayor precisión los tiempos de duración de las cirugías.

Para fundamentar este trabajo, se realizó una exhaustiva búsqueda de publicaciones científicas en las bases de datos bibliográficas ScienceDirect y Scopus. Esta investigación se enfocó en identificar las necesidades, metodologías de trabajo, desafíos y beneficios que han surgido en el sector salud al implementar tecnologías como Big Data, Machine Learning (ML) y Python para la construcción de modelos predictivos en cirugía, particularmente en la predicción de tiempos de ejecución, asignación de recursos y horizontes de planeación.

El análisis sistemático de la literatura permitió conocer las variables clave que se miden en entornos quirúrgicos para la predicción de los tiempos de duración y la asignación de recursos. Se identificaron variables relacionadas con el personal médico y de apoyo, aspectos estructurales, consideraciones administrativas y eventos imprevistos, como entradas de emergencia.

En este trabajo, se presentó la implementación de herramientas de Big Data, Machine Learning y Python, con el fin de lograr el objetivo principal: desarrollar un modelo predictivo en el sector de la salud, específicamente en el entorno quirúrgico, que sea capaz de predecir los tiempos de duración de las cirugías. Para ello, se adoptó la metodología CRISP-DM, la cual fue guía a lo largo de las etapas de comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación y despliegue del modelo.

Mediante la aplicación de CRISP-DM, se evaluaron tres escenarios específicos, identificados durante el proceso de comprensión de los datos. A partir de este análisis, se observó cómo un escenario en particular se destaca sobre los demás, presentando métricas de evaluación favorables y demostrando un rendimiento superior.

2. Planteamiento del Problema

Uno de los hospitales más representativos de la capital antioqueña actualmente cuenta con procedimientos de cirugías sin procesos de control en la asignación de tiempos, lo cual implica un desconocimiento en la capacidad requerida para la realización de las mismas, según su patología y complejidad. La variabilidad en las cirugías implica la activación de distintos recursos humanos, administrativos y económicos por lo que la escasa gestión en los tiempos genera retraso en su ejecución e impacta los cronogramas y la capacidad instalada.

Tomando en consideración lo anterior y el estudio realizado por Molina et al. (2015), los autores definen una serie de variables que afectan directamente la planificación en el uso de quirófanos y los tiempos de cirugía. En este estudio se presentó la visión holística del proceso de la planificación de cirugías, permitiendo tener un margen amplio de variables aplicables al estudio de un caso en concreto.

Por otro lado, en los últimos años ha aumentado la utilización de técnicas de aprendizaje automático en la toma de decisiones antes y durante la cirugía teniendo en cuenta la naturaleza de la misma como factor diferenciador; sin embargo, las acciones explícitas se inclinan principalmente por entender, mejorar y apoyar los recursos estratégicos en el ámbito quirúrgico.

En este contexto, los estudios que exploren alternativas para la predicción de tiempos permitirían crear modelos más acertados y dinámicos que abarquen una amplia cantidad de cirugía y aspectos que podrían determinar un mayor porcentaje en la predicción de tiempos en el procedimiento quirúrgico.

De igual manera existe un nicho de nuevo conocimiento con la posibilidad de explorar el uso de herramientas de Machine Learning en la predicción de utilización de insumos médicos y prever de mejor manera la rotación de productos usados en las diferentes áreas no solo de entornos quirúrgicos sino también de los entornos hospitalarios.

Por otro parte, dentro del amplio margen de posibles usos en los que pueden ser aplicadas las técnicas de aprendizaje automático, se genera la oportunidad de estudiar a los pacientes y predecir de manera óptima la generación de estrategias de atención más eficientes.

Es así como investigaciones como la de Vali-Siar et al., (2015) indican que los recursos utilizados en los quirófanos como los instrumentos, equipo necesario, el personal incluyendo los cirujanos especializados y los enfermeros tienen un impacto en los tiempos de ejecución de los procedimientos quirúrgicos.

Existe la posibilidad de hacer uso de las herramientas de inteligencia artificial en la predicción de eventos fortuitos dentro del entorno hospitalario como cirugías de emergencia o pacientes con características que requieren protocolos especiales de atención; indiscutiblemente las posibilidades respecto a modelos predictivos es bastante alta, gracias a la gran cantidad de focos y oportunidades de conocimiento, además de conjunción de las diferentes técnicas y posibilidades de estudio permiten que exista un mercado amplio de aplicación.

3. Justificación

En los últimos años, se ha evidenciado un crecimiento exponencial de datos en todos los ámbitos, especialmente en el clínico. En su estudio, Koziara et al. (2021) destacan el crecimiento acelerado de registros, la importancia de identificar las fuentes donde se puede extraer información valiosa del paciente, como la historia clínica electrónica, los tiempos de espera, las aplicaciones de ejercicios y la capacidad de procesar estos grandes volúmenes de información para potenciar la toma de decisiones sustentadas en la conversión de datos y mejores métricas de servicios.

Existen dos ejes para el mejoramiento de procesos y servicios: por un lado, la correcta comprensión de los flujos operacionales y, por el otro, la optimización de recursos. El sector de la salud no es ajeno a estos principios generales.

Actualmente, la planificación del uso de quirófanos se ejecuta mediante métodos heurísticos propios del sector salud. Este proceso es ejecutado por el jefe de enfermería a cargo del área de quirófano, apoyado por un auxiliar técnico administrativo. Desde la literatura, también se ha evidenciado que, por lo general, la programación está a cargo de personal de enfermería o administrativo que ejecuta su actividad con base en la práctica del cargo (Albareda et al., 2017).

La ejecución de esta actividad es de alta importancia, ya que incide directamente en la demanda de otros servicios del hospital, en la seguridad del paciente, en la satisfacción de los familiares y del personal de salud, y además, en los ingresos del servicio (Najjar Bashi, 2019). Sin embargo, pocos esfuerzos se invierten en este proceso y no existe documentación guía estandarizada.

Por eso la determinación para mejorar los procesos de planificación de tiempos de cirugías y uso de quirófanos es, en algunos casos, nula. La variabilidad de patologías, las llegadas de cirugías de urgencia y, en general, la lejanía percibida entre las áreas administrativa y la operación médica repercuten en una tendencia a la negación de optimización de recursos por parte del personal a cargo de la asignación de quirófanos y tiempos de cirugía. Este enfoque no es ajeno a lo compartido por Albareda et al. (2017). Los hospitales han invertido grandes esfuerzos en mejorar el proceso quirúrgico como tal (la atención asistencial, que va desde la preparación y el transoperatorio hasta la recuperación del paciente), pero no sucede lo mismo con la programación quirúrgica porque, al ser un proceso administrativo, pierde protagonismo por no estar asociado de manera estricta con la asistencia médica.

La gestión de un bloque quirúrgico requiere información continua y en tiempo real para su correcta planificación. Las tecnologías de la información están revolucionando la asistencia médica y mejorando la conectividad entre los agentes involucrados (Romero, 2015), conocer la capacidad instalada de los diferentes procesos permite crear cronogramas de trabajo más efectivos, minimización de reprocesos y optimización de recursos, con ellos surgen necesidades que pueden ser cubiertas con la recolección de datos, análisis e interpretación de información haciendo uso de las herramientas adecuadas para este fin.

4. Marco de Referencia

En el entorno de un Hospital Público de Medellín y en búsqueda de procesos de mejoramiento continuo y en la optimización de sus operaciones se buscó aplicar nuevas herramientas y conceptos tecnológicos que permitan aumentar la productividad mediante mejoras en la automatización y apoyo en la toma de decisiones con respecto a la planificación de tiempos óptimos de cirugías. En vista de esta necesidad, las herramientas de Machine Learning surgieron como un recurso útil para solventar los requerimientos del Hospital, es por esto por lo que se decidió agregar las siguientes definiciones al marco de referencia relacionadas con este tema.

Big Data: Se puede definir como volúmenes de datos disponibles en diversos grados de complejidad, generados a diferentes velocidades y diversos grados de ambigüedad, que no pueden procesarse utilizando tecnologías tradicionales, requieren métodos de procesamiento, algoritmos o soluciones comerciales de alto volumen y bajo estructuras de programación (Krishnan, 2013).

Machine Learning: El aprendizaje automático (ML) se refiere a la capacidad de un sistema para adquirir e integrar conocimiento a través de observaciones a gran escala, y para mejorar y expandirse mediante el aprendizaje de nuevos conocimientos en lugar de ser programado con ese conocimiento (Woolf, 2009).

Quirófano: Estructura donde se llevan a cabo actuaciones de marcada tecnicidad, es también el centro de actividad de la mayoría de sedes hospitalarias (Buisson et al., 2009).

Cirugía: Corresponde a la competencia en el diagnóstico y tratamiento de las patologías que se resuelven mediante procedimientos quirúrgicos o potencialmente quirúrgicos, tanto electivos como de urgencia de origen benigno, inflamatorio, traumático o neoplásico en los siguientes aparatos, sistemas y áreas anatómicas (Hepp et al., 2008).

Estudio de tiempos: Técnica de medición del trabajo empleada para registrar los tiempos de trabajo y actividades correspondientes a las operaciones de una tarea definida, efectuada en condiciones determinadas, con el fin de analizar los datos y poder calcular el tiempo requerido para efectuar la tarea según un método de ejecución establecido. (Ruíz, 2012).

Python: Es un lenguaje de programación ampliamente utilizado en las aplicaciones web, el desarrollo de software, la ciencia de datos y el machine learning (ML) (AWS, n.d.).

Colab: Es un producto de Google Research. Permite a cualquier usuario escribir y ejecutar código arbitrario de Python en el navegador. Es especialmente adecuado para tareas de aprendizaje automático, análisis de datos y educación (Google, n.d.).

Probabilidad: Se refiere al estudio del azar y la incertidumbre en cualquier situación en la cual varios posibles sucesos pueden ocurrir; proporciona métodos de cuantificar las oportunidades y probabilidades asociadas con varios sucesos. (Devore, 2007).

CRISP-DM: Es un marco de trabajo, creado por el grupo de empresas SPSS, NCR y Daimlerchrysler en el año 2000, con el tiempo se ha consolidado como la guía de referencia más utilizada en el desarrollo de proyectos de minería de datos, contemplado el proceso en las siguientes seis fases: A) Entendimiento del negocio, B) Entendimiento de los datos, C) Preparación de los datos, D) Modelado, E) Evaluación, y F) Despliegue (Moine et al., 2011).

5. Antecedentes

La implementación de Big Data permite mejorar la precisión en la planificación de una cirugía, ya que proporciona una amplia información sobre las condiciones actuales del paciente, lo que permite la ejecución de métodos más eficaces en la planificación del cronograma (Targarona et al., 2018).

Según Wall y Krummel (2020) en su estudio, la implementación de Big Data, Machine Learning e Inteligencia Artificial permiten compartir experiencias colectivas e individuales de otros cirujanos, lo que en conjunto se traduce en un conocimiento enriquecido que permite analizar, interpretar y desarrollar nuevas formas de enseñanza, distribución de conocimientos, técnicas y métodos para mejorar la toma de decisiones durante una cirugía de manera más oportuna y eficaz.

Teniendo en cuenta el crecimiento acelerado de datos y la importancia de identificar las fuentes donde se puede extraer información valiosa, el Big Data posibilita el procesamiento de grandes volúmenes de información y la generación de conocimientos para que el cirujano pueda comprender mejor la situación del paciente y evaluar de manera más personalizada el procedimiento quirúrgico. Todo esto es respaldado por algoritmos que permiten tomar decisiones oportunas y convenientes, impulsando la mejora de las prácticas del cirujano en cuanto al tipo de cirugía a realizar.

En salud, uno de los campos donde se emplea frecuentemente el *Big data* es en el área de atención, pero también se ha evidenciado aplicación en otras áreas como lo son las operaciones médicas que, al tener acceso al historial del paciente, imágenes y otros datos de aporte sustancial en conjunto con técnicas de análisis permitió realizar una toma adecuada de decisiones en el entorno de las operaciones de un paciente (Mehta et al. 2019).

En la mayoría de los procedimientos médicos, en particular las cirugías, se utilizan anestésicos para dormir al paciente o desensibilizar una zona específica del cuerpo con el fin de realizar el procedimiento y disminuir el dolor o la molestia. En este punto, Simpao et al. (2015) señalan que es valioso recolectar información de diversas fuentes, como la historia clínica, minería de texto y datos manuales para analizar y aplicar técnicas de Big Data y modelos de aprendizaje automático (ML) que permitan identificar información errónea y suministrar información de conocimiento al anestesiólogo sobre las mejores opciones al momento de administrar la anestesia.

La utilización de Big Data y Machine Learning ha adquirido una gran importancia en clínicas y hospitales, ya que la cantidad de fuentes de información y el crecimiento tecnológico han facilitado su

incorporación en la gestión clínica, administrativa, financiera y en áreas prácticas de las ciencias de la salud como las urgencias y las salas de operaciones. Según la revisión de la literatura, el Big Data se ha utilizado para recolectar información de fuentes propias y de terceros, lo que ha permitido adquirir datos más precisos y específicos del paciente.

Al aplicar técnicas de Machine Learning, estas pueden variar según la fuente, la estructura de los datos, el problema y el objetivo del análisis. Además, es común utilizar diferentes modelos y evaluar durante el proceso cuál ofrece los mejores resultados. Las investigaciones sugieren un interés en analizar enfermedades crónicas mediante modelos predictivos que apoyen en las cirugías y asistan en la toma de decisiones. Además, mediante Machine Learning es posible realizar una interpretación en vivo de los videos proporcionados por los instrumentos quirúrgicos, analizando cuadro por cuadro para buscar patrones e identificar irregularidades durante el procedimiento y notificar al cirujano, reduciendo así la carga de interpretación y optimizando el procedimiento quirúrgico sin reducir la habilidad del cirujano.

Durante los últimos años se ha incrementado el uso de *Big Data* y *Machine Learning* para realizar predicciones que contribuyan a la toma de decisiones en diferentes campos, como en el sector de la salud, donde las intervenciones quirúrgicas no son la excepción. Un ejemplo de esto es el estudio asociado a la cirugía ortopédica donde se ha demostrado que “la *Machine Learning* (ML) es benéfica en la estratificación y optimización del riesgo quirúrgico, predicción del diagnóstico, análisis de rentabilidad e incluso modelos de reembolso de seguros ajustados al riesgo. Varios estudios recientes han descrito el desarrollo e implementación exitosos de modelos ML para precisar y predecir la duración del caso quirúrgico, lo que resulta en una mejor precisión en la programación, una mayor eficiencia en el quirófano y costos reducidos. Sin embargo, ningún estudio ha evaluado la utilidad de ML en la predicción del tiempo operatorio y las complicaciones postoperatorias” (Lopez et al. 2022).

Como lo indican en su estudio Zhong et al. (2021) la recolección de datos usando como fuente de insumo principal el *Big Data* permite crear un modelo de aprendizaje automático PCR (regresión de componentes principales) que muestra buenos resultados al momento de predecir la duración de la hospitalización.

El estudio en cuestión se diferencia de los revisados en varios aspectos. En primer lugar, mientras que muchos de los estudios anteriores se centran en cirugías para una patología específica, el presente estudio abarca una amplia gama de cirugías sin restricciones de especialidades. Esto proporciona una visión más generalizada y la posibilidad de obtener un modelo de tiempo más amplio y aplicable a diferentes procedimientos quirúrgicos.

Otra diferencia significativa es el alcance temporal de los estudios revisados en comparación con el presente trabajo. Los estudios consultados tienen un rango de tiempo que varía entre 2 y 5 años con respecto al presente. Esto indica que el estudio actual está actualizado y refleja las condiciones y avances más recientes en el campo del Big Data y el Machine Learning aplicados a la planificación quirúrgica.

En cuanto a los modelos predictivos utilizados, los estudios revisados se enfocan en diferentes perspectivas. Algunos se basan en la regresión lineal, mientras que otros utilizan modelos de clasificación. Esta diferencia en la tipología de los modelos puede influir en los resultados y en la capacidad de predicción del tiempo quirúrgico.

Sin embargo, también se pueden identificar similitudes entre el presente estudio y los revisados. En términos de variables utilizadas, hay analogías con los estudios anteriores, lo que indica que se consideran factores comunes en la planificación quirúrgica. Esto ayuda a garantizar la relevancia y la comparabilidad de los resultados entre los diferentes estudios.

6. Objetivos

6.1. Objetivo General

Construir un modelo predictivo para calcular el tiempo de las cirugías en un Hospital Público de Medellín.

6.2. Objetivos Específicos

- Identificar y preparar los datos referentes a las variables relacionadas con el tiempo de las cirugías en un Hospital Público de Medellín
- Aplicar un modelo de regresión lineal múltiple variable para la gestión de tiempos de las cirugías.
- Evaluar el rendimiento del modelo construido para la predicción del cálculo del tiempo de las cirugías en un Hospital Público de Medellín.

7. Viabilidad

Para la construcción del modelo predictivo, se contó con los registros que permiten la consolidación de la base de datos de las cirugías realizadas y el ajuste de la información mediante un proceso de limpieza y transformación necesarios para la ejecución del modelo.

Los recursos informáticos usados en este trabajo para la aplicación de los modelos de Machine Learning se encuentran codificados en el lenguaje Python que fueron utilizados según las necesidades del ejercicio en el entorno de programación Colab. También se realizó la recolección de la información mediante toma de tiempos con cronómetro y tabulados en tablas de Excel para realizar el montaje en los softwares especificados.

La obtención de los datos se logró a través de un acuerdo de cooperación planteado entre un Hospital Público de Medellín (sección logística) y los investigadores. En dicho acuerdo se establece el alcance de ambas partes, identificando claramente los beneficios esperados y el impacto que tendrá el desarrollo de la investigación para la entidad y el sector salud. El Hospital Público de Medellín se comprometió a recolectar información acorde a un formato especificado resultado de la revisión Sistemática de Literatura (RSL) con el fin de simplificar la limpieza de los datos.

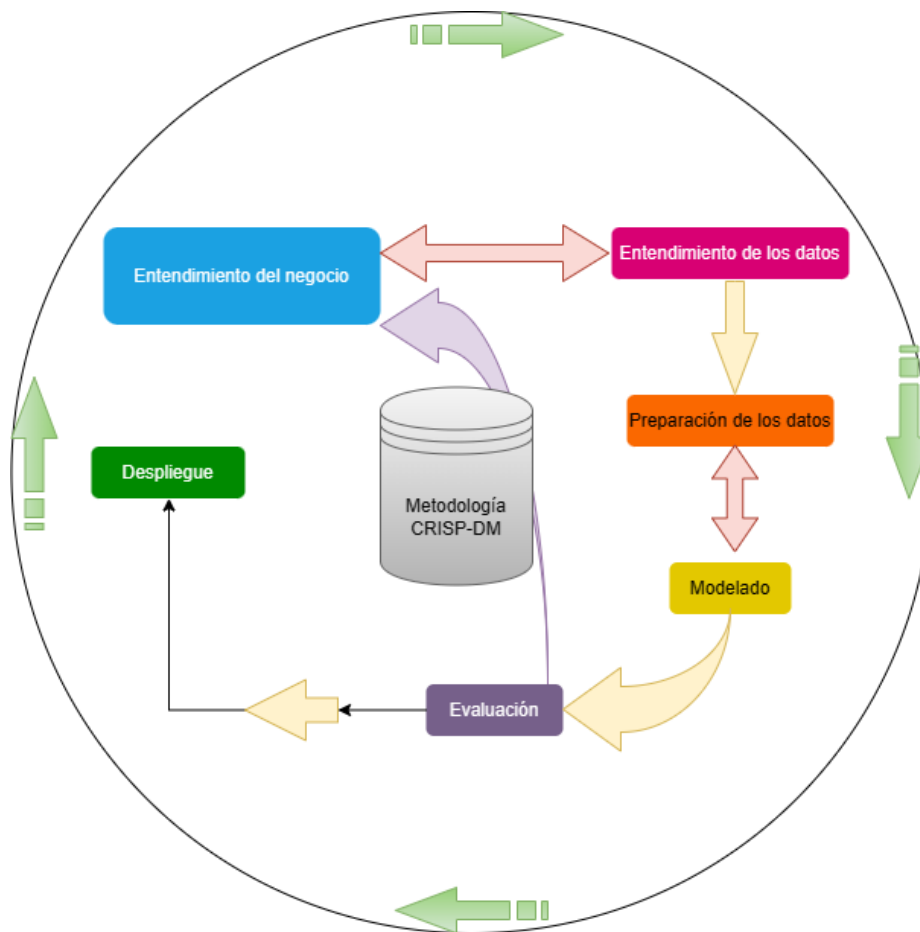
Se previó la generación de un entregable operativo y una documentación formal donde se especifique el proceso académico para la obtención de los resultados, el entregable operativo incluye manual de uso y el modelo predictivo que genere los resultados esperados según las necesidades del horizonte de planeación de uso y recursos de quirófanos en función de los tiempos de cirugía.

Se asumieron una serie de implicaciones sobre el uso de recursos para el desarrollo del trabajo, inicialmente el préstamo de personal del hospital para la toma de tiempos y los espacios de retroalimentación con los encargados de soporte logístico del hospital, esto implica una variación propia de las funciones normalmente generadas por el equipo de trabajo. De igual forma los encuentros y viajes de verificación del proceso generaron costos de traslado y de nuevo tiempo administrativo.

8. Metodología

Según Schröer et al. (2021), CRISP-DM es el estándar y un modelo de proceso independiente de la industria para aplicar proyectos de minería de datos. Es la metodología seleccionada por el equipo de trabajo que permitió resolver el problema de investigación utilizando las siguientes fases.

Figura 1. Diagrama de la metodología CRISP-DM



Fase I. Entendimiento del negocio

En un Hospital Público de Medellín seccional logística, surgió la necesidad de identificar y predecir los tiempos de las cirugías para poder activar la cantidad adecuada de recursos materiales y humanos que intervienen en el proceso y hacen uso de los quirófanos.

Actualmente la planeación es ejecutada de forma manual por el personal encargado de realizar las asignaciones, y es aquí donde surgió la necesidad de generar un análisis de los tiempos necesarios para los servicios ejecutados en el área de logística con el fin de realizar una distribución de los quirófanos de forma sistematizada y óptima en función de los datos recolectados.

Para el estudio se consideró realizar una base de datos teniendo en cuenta la RSL que se hizo previamente de estudios relacionados, se resalta la definición de las variables desde la cantidad de personas programadas para las cirugías, el tipo de patología, la asignación de quirófano, los tiempos esperados y finalmente los tiempos ejecutados.

En esta fase el enfoque fue modelar una base de datos basada en las variables encontradas en la revisión sistemática de literatura (RSL) esto facilitó las personas encargadas de recolectar la información su comprensión y permitirá identificar posibles problemas de calidad e información oculta.

Fase II. Entendimiento de los datos

Las fuentes de información provienen directamente de los recursos operativos del hospital y están desarrollados principalmente en términos técnicos del sector salud. Inicialmente, para la estructuración y entendimiento de los datos, se debió validar la tipología de la cirugía, especialidad y complejidad para generar uniformidad en la información que permitan su fácil interpretación.

Por otro lado, las características de los datos también están asociadas a los eventos de medición, en este caso en función del tiempo de ejecución de cirugía, la homogeneidad en los formatos temporales ya sea en horas, fechas y demás debió ser corroborada a fin de minimizar errores de deducción.

Finalmente, los recursos humanos presentes en el proceso tanto activos (personal médico) como pasivos (pacientes) son categorizados según cualidades diferenciales en el proceso sin afectar el *Habeas Data* de los actores.

Fase III. Preparación de los datos

Esta fase se enfocó principalmente en analizar los datos recolectados, depurar la información y generar atributos nuevos si es necesario. Dando como resultado final un set de datos limpio y listo para ser utilizado en las herramientas de modelado.

Se contó con una fuente de información recolectada por personal propio del hospital con ejecuciones reales de cirugías en espacios de tiempo aleatorio con el fin de garantizar variabilidad en los datos; se obtuvieron registros en un rango temporal de tres meses de cirugías ejecutadas a personas mayores de edad, los tiempos de ejecución, intervalos de limpieza y planeación son capturados en registros de hora de inicio, hora de fin; respecto a los factores humanos se centra en la cantidad personal médico y de limpieza por cirugía, sexo y edad del paciente.

Para la preparación de los datos inicialmente se estandarizaron los tiempos en minutos para cada una de las cirugías, se ajustaron fechas y demás variables en un formato estandarizado, se eliminaron errores de captura, datos nulos y filas incompletas. De igual forma, se descartaron columnas de información que no generan valor al estudio, tales como consecutivos, observaciones sin trazabilidad, tiempos de limpieza, filas de subtítulos, entre otras. Finalmente se realizó un ejercicio de validación aleatoria de correlaciones de información y dispersión de datos atípicos.

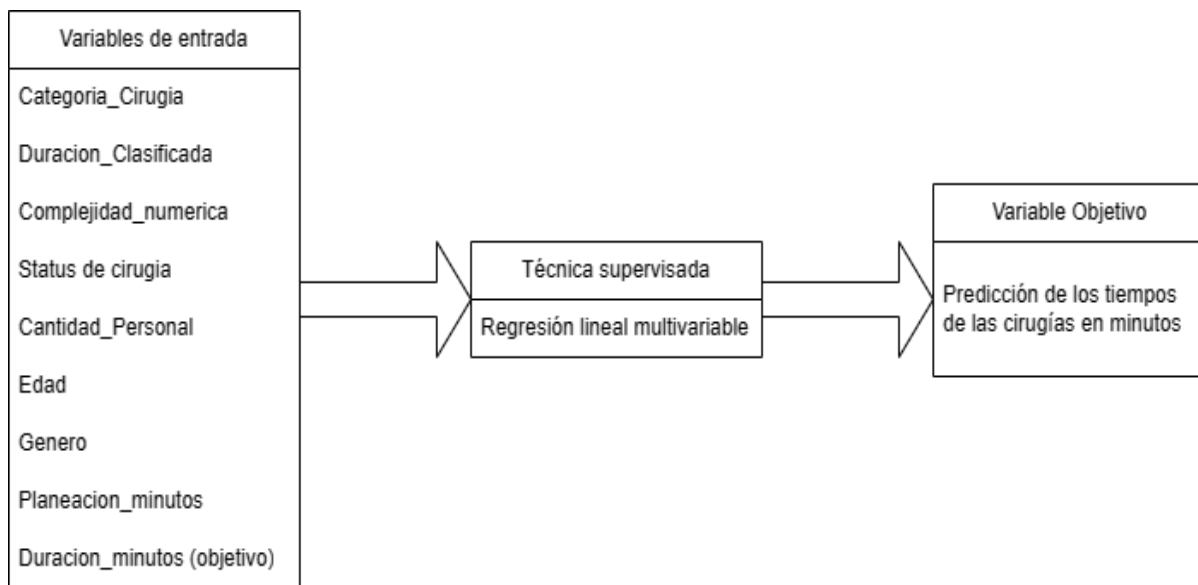
Fase IV. Modelado

En esta fase se ejecutó la técnica de Machine Learning de regresión lineal multivariable aplicado a diferentes escenarios, con el fin de poder generar un modelo predictivo de la variable objetivo utilizando los datos recolectados.

Regresión lineal multivariable

Esta técnica permitió ver la correlación que existe entre las variables que fueron utilizadas en el modelo, teniendo en cuenta las categorías de cirugías ya dispuestas y otras variables como: Duración Clasificada, Complejidad Numérica, Status de cirugía, Cantidad Personal, Género, Edad y Planeación Minutos. De esta forma, se configuró el algoritmo para agregar o quitar variables que permitieron afinar el modelo predictivo para obtener la variable objetivo representada en la siguiente figura.

Figura 2 Modelo predictivo de regresión lineal



Fase V. Evaluación

Con el modelo construido anteriormente y ya aplicado a la *Data* se procedió a realizar los controles de calidad pertinentes analizando los resultados obtenidos y se contrastaron con los datos reales. Mediante la utilización de un modelo Train/Test Split se separó un porcentaje de datos para realizar el entrenamiento del modelo (80%) y otro para realizar el test (20%) y se contrastó que la predicción hecha sea acorde a los datos de validación.

Por medio de estadísticos de verificación de errores, como el error medio cuadrático (RMSE), error medio absoluto (MAE) y el coeficiente de determinación (R²), se verificó la calidad del modelo.

Fase VI. Despliegue

Una vez realizados los controles de calidad y la evaluación de los resultados del modelo se generó un producto que usa *Machine Learning* en la predicción de tiempos de cirugía.


9. Resultados

9.1. Entendimiento de los datos

Las cirugías son únicas debido a las características de cada paciente. Es importante resaltar que, aunque hay cirugías enfocadas en una misma patología, no necesariamente son ejecutadas por el especialista de la lesión; esto sucede inicialmente debido al número de cirujanos especialistas en contraste con el número de cirujanos generales disponibles en turno, adicionalmente por la llegada de cirugías no programadas (urgencias), entre otras. De igual forma existen algunas cirugías que cuentan con la participación de cirujanos generales y especialistas simultáneamente, en estos casos se tomó en consideración el cirujano principal del procedimiento para su categorización, que es generada por el mismo personal del hospital.

En total se contó con 29 categorías, organizadas por volumen de ejecución, la categoría con mayor número de registros corresponde a la ejecutada por cirujanos generales y cuenta con 52% del total de los datos (Figura 3).

Figura 3. Categorías de cirugías



El tiempo promedio de ejecución por cirugía es de 142 minutos, con un máximo de 560 minutos efectuados en una cirugía de trasplante hepático y un mínimo de 21 minutos para una intervención de llegada Urgente. De igual forma, como se puede evidenciar en la figura 4, las cirugías hepatobiliares son las que cuentan con la media de duración más elevada cercana a las 8 horas (453 minutos), seguida por aquellas de carácter endocrinólogo.

Figura 4. Tiempo de duración promedio por cirugía

Categoría Cirugía	Promedio de Tiempo Ejecución MINUTOS
HEPATOBILIAR	453,00
ENDOCRINOLOGO	234,00
COLOPROCTÓLOGO	173,46
NEFROLOGIA	169,50
ANGIÓLOGO	167,60
TRAUMATOLOGÍA	165,65
NEFROLOGO	164,35
Total	142,66

En el mismo orden de ideas existe una distribución respecto al género del paciente (Figura 5) y un rango promedio de edad entre los 60 y 40 años (Figura 6) con valores mínimos y máximos cercanos a los 22 y 91 años.

Figura 5. Género.


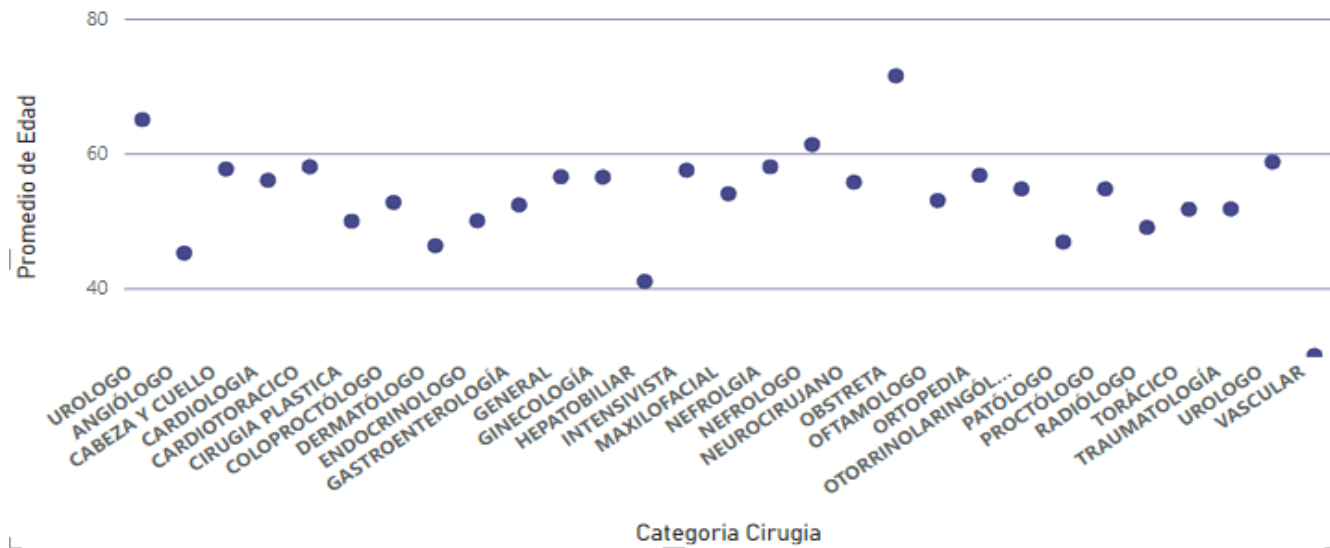



Figura 6. Promedio edad




Por otro lado, se contó con un horizonte de ejecución que se desarrolla mediante dos tipos de asignaciones o estatus: las que han sido previamente programadas y aquellas generadas de manera aleatoria en el día a día (urgentes). Es importante tener visibilidad en el peso porcentual de la tipología, compartido en la Figura 7, debido a que las primeras cuentan con un mayor control en el tiempo de ejecución en contraste con las urgentes que se ajustan a lo estimado al momento de su desarrollo.

Figura 7. Estatus de cirugía




En línea con el estatus de las cirugías, estas también están atadas a una clasificación según su nivel de complejidad Alta, Media o Baja (Figura 8), se cuenta con un comportamiento relativamente uniforme en su peso porcentual.

Figura 8. Nivel de complejidad.




Respecto a los recursos humanos habilitados para el trabajo quirúrgico, estos están repartidos bajo diferentes roles y funciones, algunos de ellos están vinculados laboralmente al hospital y otros son prestadores externos; esta caracterización delimitó la captura de la información según la cantidad de personal activo en la cirugía sin distinción individual. El promedio de personal en quirófanos es de 7, con mínimo y máximo de 4 y 10 personas respectivamente. Como se muestra en la Figura 9, en promedio las cirugías de colon y traumatología son las que cuentan con mayor cantidad de recursos humanos activos en el quirófano.

Figura 9. Personal activo en el quirófano.



Finalmente, en la Figura 10, se contrasta la cantidad de personal médico según la complejidad, se evalúa que el número de personal en el quirófano no está estrictamente relacionado a la complejidad (Figura 8).

Figura 10. Promedio personal médico según complejidad.



9.2. Preparación de los datos

Al revisar el set de datos entregado por el hospital se encontró que los datos estaban bastantes completos en cada uno de sus registros, los tipos de datos fueron los esperados (enteros, fechas y texto), no se encontraron espacios nulos, también se observa las columnas que fueron utilizadas para recolectar la información (Figura 11).

Figura 11. Columnas contenidas en el archivo insumo y su tipo.

#	Column	Non-Null Count	Dtype
0	Consecutivo	1714 non-null	int64
1	Dia de la semana	1714 non-null	object
2	Fecha	1714 non-null	datetime64[ns]
3	# Qurifoano	1714 non-null	int64
4	Status de cirugía	1714 non-null	object
5	Tipo de cirugía o Especialidad	1714 non-null	object
6	Categoría Cirugía	1714 non-null	object
7	Sexo Paciente	1714 non-null	object
8	Edad	1714 non-null	int64
9	Complejidad	1714 non-null	object
10	Cantidad de personal medico	1714 non-null	int64
11	Hora inicio	1714 non-null	object
12	Hora Fin	1714 non-null	object
13	Hora inicio.1	1714 non-null	object
14	Hora Fin.1	1714 non-null	object
15	Cantidad Personal limpieza	1714 non-null	int64
16	Hora inicio.2	1714 non-null	object
17	Hora Fin.2	1714 non-null	object
18	Tiempo Planeación	1714 non-null	object
19	Tiempo Ejecución	1714 non-null	object
20	Tiempo Limpieza	1714 non-null	object
21	Tiempo Planeación Minutos	1714 non-null	int64
22	Tiempo Ejecución MINUTOS	1714 non-null	int64
23	Tiempo Limpieza MINUTOS	1714 non-null	int64

Al realizar una exploración profunda del contenido de cada uno de las columnas se encontró columnas de tiempo que ya se encuentran convertidas en minutos en un formato numérico entero, también se identifican columnas como: Fecha, Consecutivo , Dia de la semana, Hora inicio, Hora Fin , Hora inicio.1, Hora Fin.1, Cantidad Personal limpieza, Cantidad Personal limpieza, Hora inicio.2, Hora

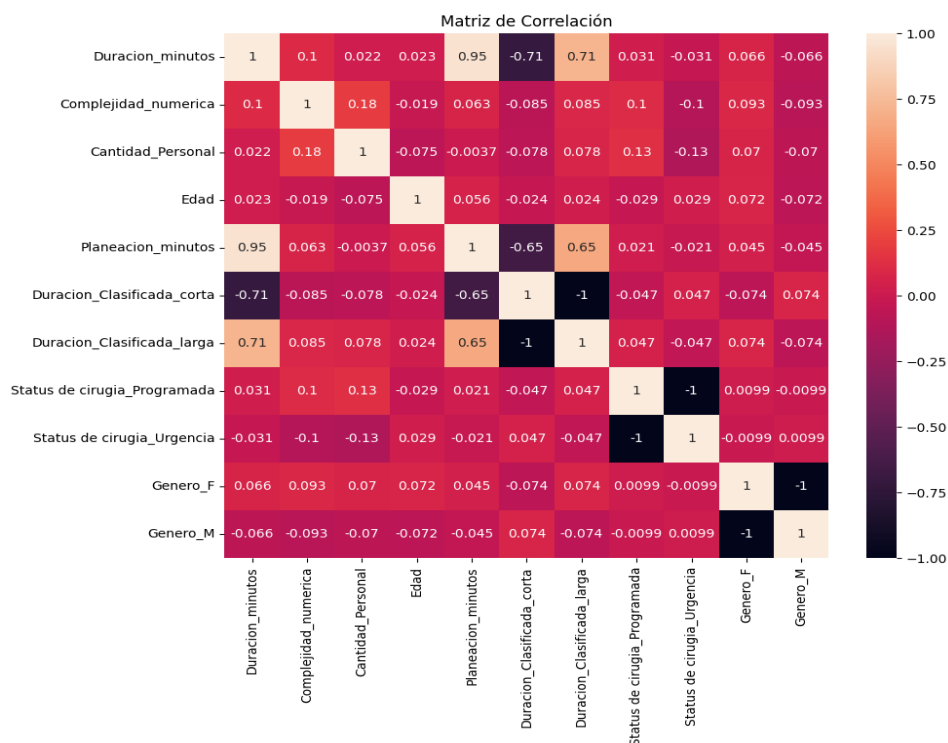
Fin.2, Tiempo Ejecución, Tiempo Limpieza, Tiempo Planeación, Tiempo Limpieza MINUTOS, Tipo de cirugía o Especialidad, que no aportan información relevante al estudio, estas columnas no fueron consideradas y posteriormente fueron eliminadas para así obtener un set de datos final para entrenar los modelos (Figura 12).

Figura 12. Columnas finales elegidas para entrenar el modelo.

#	Column	Non-Null Count	Dtype
0	Complejidad_numerica	298 non-null	int64
1	Cantidad_Personal	298 non-null	int64
2	Edad	298 non-null	int64
3	Planeacion_minutos	298 non-null	int64
4	Duracion_Clasificada_corta	298 non-null	uint8
5	Duracion_Clasificada_larga	298 non-null	uint8
6	Status de cirugia_Programada	298 non-null	uint8
7	Status de cirugia_Urgencia	298 non-null	uint8
8	Genero_F	298 non-null	uint8
9	Genero_M	298 non-null	uint8

Con las columnas ya definidas se procedió a realizar una matriz de correlación no sin antes organizar las columnas de tipo object (Figura 11) en numéricas por medio de la función “get dummies” que permite crear una columna por cada tipo de dato object. Con todas las dummies necesarias ya creadas se procedió a realizar la matriz de correlación (Figura 13) donde se contrasta que no hay una alta correlación entre otras variables distintas a sí mismas.

Figura 13. Matriz de correlaciones



9.3. Modelado

En esta fase, se decidió dividir el conjunto de datos para evaluar el modelo de regresión lineal multivariable en tres escenarios diferentes, con el objetivo de revisar las métricas arrojadas. Se optó por seleccionar las dos categorías con mayor cantidad de registros en el conjunto de datos (general y ortopedia), creando un modelo para cada una de ellas, y finalmente se evaluó el conjunto completo sin discriminación.

Es importante destacar que en los tres escenarios se utilizaron las columnas previamente organizadas (como se muestra en la Figura 12, de la sección 9.2) del conjunto de datos, colocando en el eje X las variables de entrada, duración clasificada, complejidad numérica, estado de la cirugía, cantidad de personal, género, edad y tiempo de planificación. En el eje Y (variable objetivo) se ubicó la duración de la cirugía. Una vez que se ajustaron las variables en cada uno de los ejes, se procedió a entrenar los modelos de los escenarios propuestos.

9.4. Evaluación

Después de entrenar el modelo, se evaluó su rendimiento utilizando el conjunto de datos de entrenamiento, que representó el 20% del total de registros. Se emplearon las métricas de Intercepto, Error Cuadrático Medio (MSE), Raíz error Cuadrático Medio (RMSE), Error absoluto medio (MAE) y R2 Score para evaluar el desempeño del modelo. En la tabla 1 se encuentran las fórmulas de las métricas.

Tabla 1. Fórmulas de las métricas de evaluación del modelo.

<p>Ecuación regresión lineal múltiple</p>	$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$	<p>Y es la variable dependiente o variable a predecir.</p> <p>X_1, X_2, \dots, X_p son las variables independientes o características que se utilizan para predecir Y.</p> <p>$\beta_0, \beta_1, \beta_2, \dots, \beta_p$ son los coeficientes de regresión que representan la relación entre las variables independientes y la variable dependiente.</p> <p>ε es el término de error.</p>
<p>Error cuadrático medio (RMSE):</p>	$\sqrt{\text{sumatoria}((Y_i - \bar{Y})^2) / n}$	<p>Y_i es el valor observado de la variable dependiente.</p> <p>\bar{Y} es el valor predicho para la variable dependiente.</p>
<p>Error Absoluto medio (MAE)</p>	$\text{sumatoria} (Y_i - \bar{Y}) / n$	<p>n es el número de observaciones.</p>
<p>Coficiente de determinación R^2</p>	$R^2 = 1 - (SS_{\text{res}} / SS_{\text{tot}})$	<p>SS_{res} es la suma de los cuadrados de los residuos (o errores) de la regresión.</p> <p>SS_{tot} es la suma total de los cuadrados.</p>

Evaluar las métricas de los modelos permitió interpretar con mayor claridad los resultados y ajustar el modelo en caso de ser necesario, a continuación, tenemos las siguientes métricas para cada uno de los escenarios:

9.4.1 Escenarios categoría de cirugía general

Tabla 2. Coeficientes resultados del modelo categoría de cirugía general.

Variable	Coeficiente
Complejidad_numerica	-2.113
Cantidad_Personal	-0.518
Edad	0.00126
Planeacion_minutos	0.748
Duracion_Clasificada_corta	-16.962
Status de cirugia_Programada	0.962
Genero_M	-1.434

En la Tabla 2 se presentaron los resultados que mostraron la magnitud de afectación de las variables predichas del modelo en función del valor absoluto de sus coeficientes.

Los resultados revelaron que las variables que tuvieron un mayor impacto en la predicción de los tiempos fueron: la duración (categoría larga). Cuando la duración se clasificaba como larga, se observó un incremento de aproximadamente 16.96 minutos en la variable de respuesta en comparación con la duración clasificada como corta, manteniendo constantes las demás variables.

Por otro lado, la complejidad (-2.113) y el género del paciente (-1.434) mostraron una afectación inversa. Estas variables tendieron a disminuir entre 2 y 1 minutos el valor predictivo del modelo, manteniendo constantes las demás variables.

Las variables restantes tuvieron una incidencia menor en los tiempos de cirugía. Sin embargo, aún conservan un impacto en el modelo, lo cual mantiene su nivel de importancia para la capacidad predictiva del ejercicio.

Tabla 3. Métricas resultado del modelo categoría de cirugía general.

Nombre métricas	Resultado
Intercepto	35.76
Raíz error Cuadrático Medio (RMSE)	21.12
Error absoluto medio (MAE)	15.24
R2 Score	0.92

El intercepto en la tabla 3 es de 35.76, lo que significa que, si todas las variables independientes son cero, se esperaría que la duración de la cirugía fuera de aproximadamente 36 minutos. El RMSE obtenido es de 21.12, este valor indica la distancia promedio entre los valores predichos del modelo y los valores reales en el conjunto de datos. El MAE obtenido es de 15.2, indica que el error promedio absoluto entre los valores reales y los valores predichos por el modelo es de 15.2 minutos. Finalmente, el R2 Score es de 0.92, lo que indica que las variables independientes en el modelo explican el 92% de la variabilidad en la duración de la cirugía generando una confiabilidad sana en los tiempos de predicción.

9.4.2 Categoría de cirugía ortopedia

Tabla 4. Coeficientes resultados del modelo categoría de cirugía ortopedia.

Variable	Coeficiente
Complejidad_numerica	1.867
Cantidad_Personal	0.168
Edad	-0.123
Planeacion_minutos	0.765
Duracion_Clasificada_corta	-15.14
Status de cirugia_Programada	-0.168
Genero_M	-0.991

En la Tabla 4 se presentan los resultados que mostraron la magnitud de afectación de las variables predichas del modelo en función del valor absoluto de sus coeficientes.

Los resultados revelaron que la variable que tuvo un mayor impacto en la predicción de los tiempos fue la duración. Cuando la duración se clasificaba como larga, se observó un incremento de aproximadamente 15.14 minutos en la variable de respuesta. Sin embargo, cuando la duración se clasificaba como corta, se observó una disminución de 15.14 minutos en la variable de respuesta, manteniendo constantes las demás variables. De igual forma, la complejidad aumentó en aproximadamente 2 minutos el valor predictivo del modelo.

Por otro lado, las variables restantes tuvieron una incidencia menor en los tiempos de cirugía. Sin embargo, aún conservan un impacto en el modelo, lo cual mantiene su nivel de importancia para la capacidad predictiva del ejercicio.

Tabla 5. Métricas resultado del modelo categoría de cirugía ortopedia.

Nombre métricas	Resultado
Intercepto	28.53
Raíz error Cuadrático Medio (RMSE)	26.91
Error absoluto medio (MAE)	17.38
R2 Score	0.912

En la tabla 5, el intercepto es de 28.5, es decir que, si todas las variables independientes son cero, se esperaría que la duración de la cirugía fuera de aproximadamente 28.5 minutos. El valor del RMSE es de 26.91, este valor indica la distancia promedio entre los valores predichos del modelo y los valores reales. Con el valor del MAE es de 17.4, lo que indica que el error promedio absoluto entre los valores reales y los valores predichos por el modelo es de 17.4 minutos. El valor de R2 es de 0.91, lo que indica que las variables independientes en el modelo explican el 91% de la variabilidad en la duración de la cirugía, que es una medida ligeramente inferior a la del modelo de la tabla 3.

9.4.3 Todo el conjunto de datos

Tabla 6. Coeficientes resultados del modelo de todos los datos.

Variable	Coeficiente
Complejidad_numerica	-0.388
Cantidad_Personal	-0.109
Edad	0.012
Planeacion_minutos	0.780
Duracion_Clasificada_corta	-15.557
Status de cirugia_Programada	1.040
Genero_M	-0.163

En la Tabla 6 se presentaron los resultados que mostraron la magnitud de afectación de las variables predichas del modelo en función del valor absoluto de sus coeficientes.

Los resultados revelaron que las variables que tuvieron un mayor impacto en la predicción de los tiempos fueron: la planeación, el estimado de la cirugía, que incrementó aproximadamente 8 minutos en la variable de respuesta. De igual manera, la edad, el género del paciente, la duración (categoría larga o corta) y el estatus de la cirugía (programada o de urgencias) tendieron a variar entre 1 y 2 minutos en el valor predictivo del modelo.

Las variables restantes tuvieron una incidencia menor en los tiempos de cirugía. Sin embargo, aún conservan un impacto en el modelo, lo cual mantiene su nivel de importancia para la capacidad predictiva del ejercicio.

Tabla 7. Métricas resultado del modelo de todos los datos.

Nombre métricas	Resultado
Intercepto	26.22
Raíz error Cuadrático Medio (RMSE)	34.29
Error absoluto medio (MAE)	19.25
R2 Score	0.84


En la tabla 7, el intercepto es de 26.2, lo que significa que, si todas las variables independientes son cero, se esperaría que la duración de la cirugía fuera de aproximadamente 26 minutos. El valor del RMSE es de 34.39, indicándonos la distancia promedio entre los valores predichos del modelo y los valores reales. Con el valor del MAE es de 19.25, lo que indica que el error promedio absoluto entre los valores reales y los valores predichos por el modelo es de 19.25 minutos. El valor de R2 es de 0.84, lo que indica que las variables independientes en el modelo explican el 84% de la variabilidad en la duración de la cirugía, que es una medida significativamente inferior a los modelos de las tablas 3 y 5. En resumen, la tabla 3 muestra que el modelo tiene un buen ajuste y rendimiento de predicción.

9.5. Despliegue

Para la implementación del modelo predictivo descrito previamente, se utilizó la librería "pickle". Mediante el uso de esta librería, se generaron tres modelos basados en regresión lineal multivariable, los cuales se guardan como archivos binarios con extensión. pkl.

La utilización de la librería "pickle" permitió simplificar el proceso de despliegue, ya que permitió el almacenamiento de los modelos en un formato que puede ser fácilmente cargado y utilizado posteriormente. Los archivos. pkl resultantes contienen los modelos correspondientes a las cirugías generales, las cirugías especializadas en ortopedia y el conjunto global de las 29 especialidades médicas existentes como se puede ver en la siguiente figura.

Figura 14. Archivos binarios generados de los modelos



10. Conclusiones

El desarrollo de un modelo de Machine Learning basado en regresión lineal multivariable para predecir los tiempos de cirugía ha arrojado resultados prometedores. El modelo ha logrado una precisión cercana al 88% en los datos de evaluación, lo que demuestra su rendimiento predictivo. Se han considerado 10 variables de las 23 posibles, relacionadas principalmente con los tiempos de cirugía, aunque existen otras variables que podrían mejorar la efectividad del modelo.

Al analizar los escenarios propuestos, se observó que las cirugías realizadas por médicos generales, así como las cirugías de la categoría de ortopedia, obtuvieron una precisión del 92% y 91%, respectivamente. Sin embargo, al considerar el conjunto global de todas las categorías médicas, la precisión disminuye ligeramente al 84%. Esto se debió a la alta variabilidad de patologías presentes en cada especialidad, lo que dificulta la predicción precisa.

La estimación de los coeficientes para cada uno de los escenarios propuestos evidenció, en términos generales, que la variable que tuvo una mayor incidencia en los tiempos de predicción fue la duración categoría larga (cirugías que sobrepasan los 120 minutos de ejecución). Esta variable varió en aproximadamente 15 minutos en los resultados del modelo, lo que indica que las cirugías de larga duración presentan una mayor inestabilidad en su predicción al momento de ser ejecutadas.

Es importante resaltar que a medida que disminuye el porcentaje de predicción en cada escenario, también se reduce el valor del intercepto. El intercepto representa el tiempo estimado por cirugía cuando todas las variables independientes son cero. Este ajuste en el modelo refleja un aumento en el tiempo estándar para una cirugía, lo cual concuerda con las expectativas basadas en la media de los datos.

Considerando el amplio rango temporal de las cirugías estudiadas, que variaron desde los 21 hasta los 560 minutos, los desfases en las predicciones se mantuvieron dentro de un rango aceptable de aproximadamente 15 a 19 minutos. Estos valores son realistas, ya que en la práctica las cirugías están sujetas a eventos independientes con poca capacidad de control. Esto reafirma el potencial de los modelos de Machine Learning en el entorno quirúrgico.

Finalmente, los resultados obtenidos en este estudio demuestran que los tiempos de cirugía analizados son consistentes con los resultados esperados según los datos de entrenamiento. El uso eficiente de los quirófanos depende de múltiples variables, pero puede ser modelado de manera efectiva para generar panoramas de acción acertados. Es importante tener en cuenta que los resultados proporcionados por el modelo de Machine Learning son una guía operativa, y al final debe existir la intervención de un profesional competente que valide y ratifique dichos resultados.

11. Recomendaciones

En entornos hospitalarios, se vislumbra un potencial ilimitado y numerosas oportunidades para profundizar en las capacidades de las herramientas de Machine Learning (ML). Este trabajo representó un acercamiento inicial a la predicción de tiempos en ambientes quirúrgicos, utilizando un modelo supervisado de regresión lineal multivariable. Sin embargo, es importante destacar que existe la posibilidad de emplear otros modelos supervisados, tanto de regresión como de clasificación, según las necesidades específicas. Por ejemplo, si se desea examinar detalladamente el impacto de las patologías preexistentes, se pueden generar clústeres de posibles complicaciones y determinar potenciales aumentos o disminuciones en los tiempos de cirugía.

Además, es fundamental reconocer que el servicio de cirugía implica un trabajo en equipo, por lo que una buena organización es esencial para administrar los recursos de manera adecuada. Desde una perspectiva predictiva, hay una oportunidad para comprender y cuantificar la influencia de la experiencia del cirujano y/o del equipo quirúrgico al momento de establecer los tiempos de cirugía. Esto permitiría generar cronogramas más precisos y personalizados de planificación, minimizando la sobrecarga o la subutilización de recursos en cada cirugía.

Por último, es importante mencionar que existen numerosas especialidades quirúrgicas que no fueron abordadas en este estudio. Se realizaron pruebas específicamente para las especialidades de ortopedia y medicina general, pero aún se pueden realizar pruebas adicionales para las diversas categorías dentro de la esfera médica. Sería factible desarrollar modelos de Machine Learning (ML) de regresión para estimar los tiempos óptimos de duración de cada consulta médica, considerando variables como la edad, los antecedentes clínicos y otros factores relevantes. En definitiva, los modelos de ML ofrecen grandes posibilidades para potenciar la planificación y la toma de decisiones en los entornos hospitalarios.

12. Referencias

- Albareda, J., Clavel, D., Mahulea, C., Blanco, N., Ezquerro, L., & Silva, J. M. (2017). Do we perform surgical programming well? How can we improve it? *Revista Española de Cirugía Ortopédica y Traumatología*, 61(6), 375-382. <http://doi.org/10.1016/j.recot.2017.07.006>
- AWS. (n.d.). ¿Qué es Python? Retrieved October 9, 2022, from <https://aws.amazon.com/es/what-is/python/>
- Buisson, P., Gunepin, F.-X., & Levadoux, M. (2009). Organización del quirófano. *EMC - Técnicas Quirúrgicas - Ortopedia y Traumatología*, 1(2), 1–16. [https://doi.org/10.1016/S2211-033X\(09\)70103-3](https://doi.org/10.1016/S2211-033X(09)70103-3)
- Devore, J. L. (2007). *Probability and Statistics for Engineering and the Sciences* (7). Duxbury Press. 1-9.
- Fredy O. Pérez Ramírez, L. C. R. C. S. E. U. M. P. (2007). *Introducción a las series de tiempo. Métodos paramétricos*. Alianza Editorial, 13-14.
- Galán Cortina, V. (2015). *Aplicación de la metodología CRISP-DM a un proyecto de minería de datos en el entorno universitario*. Universidad Carlos III de Madrid. https://earchivo.uc3m.es/bitstream/handle/10016/22198/PFC_Victor_Galan_Cortina.pdf
- Google. (n.d.). Google Colab. Retrieved October 4, 2022, from <https://research.google.com/colaboratory/intl/es/faq.html>
- Gómez, O. S. (n.d.). Propuesta de mejora sobre la primera etapa del modelo de proceso KDDM, CRISP-DM Related papers. Retrieved October 5, 2022, from <http://www.sigkdd.org/>
- Hepp, J. K., Csendes, A. J., Ibáñez, F. C., Llanos, O. L., & San Martín, S. R. (2008). Programa de la especialidad Cirugía General: Definiciones y propuestas de la Sociedad de Cirujanos de Chile. *Revista Chilena de Cirugía*, 60(1), 79–85. <https://doi.org/10.4067/S0718-40262008000100017>

- HERNANDEZ, V. (2020). Medellín. Metodología para entandrizar el proceso de programación de salas de cirugía Recuperado de https://repository.eafit.edu.co/bitstream/handle/10784/17031/Vanessa_HernandezQuiceno_2020.pdf?sequence=2
- Koziara, M., Gaukroger, A., Hing, C., & Eardley, W. (2021). Introduction to Big Data in trauma and orthopaedics. *Orthopaedics and Trauma*, 35(2), 84–89. <https://doi.org/10.1016/J.MPORTH.2021.01.004>
- Krishnan, K. (2013). Introduction to Big Data. *Data Warehousing in the Age of Big Data*, 3–14. <https://doi.org/10.1016/B978-0-12-405891-0.00001-5>
- Lopez, C. A., Constant, M., Anderson, M. L., Confino, J., Lanham, N. S., & Jobin, C. M. (2022). Using Machine Learning methods to predict prolonged operative time in elective total shoulder arthroplasty. *Seminars in Arthroplasty: JSES*, 32(3), 452-461. <https://doi.org/10.1053/j.sart.2022.01.003>
- Mehta, N., Pandit, A., & Shukla, S. (2019). Transforming healthcare with big data analytics and artificial intelligence: A systematic mapping study. *Journal of Biomedical Informatics*, 100, 103311. <https://doi.org/10.1016/J.JBI.2019.103311>
- Moine, J. M., Haedo, A. S., & Gordillo, S. E. (2011). Estudio comparativo de metodologías para minería de datos. XIII Workshop de Investigadores En Ciencias de La Computación.
- Molina-Pariente, J. M., Hans, E. W., Framinan, J. M., & Gomez-Cia, T. (2015). New heuristics for planning operating rooms. *Computers & Industrial Engineering*, 90, 429–443. <https://doi.org/10.1016/J.CIE.2015.10.002>
- Najjar Bashi, A., & Lim, G. J. (2019). A variability reduction method for the operating room scheduling. *Operations Research for Health Care*, 20, 25-32. <https://doi.org/10.1016/j.orhc.2019.01.001>
- Petit, A. G. (2003). Modelado y simulación. Aplicación a procesos logísticos de fabricación y servicios. UPC, S.L., Edicions, 8-12.
- Romero García E, Lacruz P, Checa Barambio C, Alfaro Rubio A, Dapena Ortiz D, Rollán García P, Gil Suay V (2015). El poder de la planificación en el bloque quirúrgico. *Gestión y Evaluación de Costes Sanitarios* vol 15, 75-92

- Ruíz, C. J. A. (2012). Mejora de métodos y tiempos de fabricación (Productividad industrial no 1) (1.a ed.). Marcombo, 43-45.
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Simpao, A. F., Ahumada, L. M., & Rehman, M. A. (2015). Big data and visual analytics in anesthesia and health care. *British Journal of Anaesthesia*, 115(3), 350–356. <https://doi.org/10.1093/BJA/AEU552>
- Targarona, E. M., Balla, A., & Batista, G. (2018). Big Data and Surgery: The Digital Revolution Continues. *Cirugía Española (English Edition)*, 96(5), 247-249. <https://doi.org/10.1016/J.CIRENG.2018.05.005>
- Vali-Siar, M. M., Gholami, S., & Ramezani, R. (2018). Multi-period and multi-resource operating room scheduling under uncertainty: A case study. *Computers & Industrial Engineering*, 126, 549–568. <https://doi.org/10.1016/J.CIE.2018.10.014>
- Wall, J., & Krummel, T. (2020). The digital surgeon: How big data, automation, and artificial intelligence will change surgical practice. *Journal of Pediatric Surgery*, 55, 47–50. <https://doi.org/10.1016/J.JPEDIURG.2019.09.008>
- Woolf, B. P. (2009). Machine Learning. *Building Intelligent Interactive Tutors*, 221–297. <https://doi.org/10.1016/B978-0-12-373594-2.00007-1>
- Zhong, H., Wang, B., Wang, D., Liu, Z., Xing, C., Wu, Y., Gao, Q., Zhu, S., Qu, H., Jia, Z., Qu, Z., Ning, G., & Feng, S. (2021). The application of machine learning algorithms in predicting the length of stay following femoral neck fracture. *International Journal of Medical Informatics*, 155, 104572. <https://doi.org/10.1016/J.IJMEDIINF.2021.104572>