



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

PREDICCIÓN DE LA DEMANDA DE LAS SOLICITUDES DE INTERCONSULTAS DE  
ESPECIALIDADES MÉDICAS Y ODONTOLÓGICAS DEL SSMSO

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

BRIAN ESTEBAN FLEIDERMAN SASSO

PROFESOR GUÍA:  
PABLO MARÍN VICUÑA

MIEMBROS DE LA COMISIÓN:  
CAROLINA SEGOVIA RIQUELME  
FELIPE VILDOSO CASTILLO

SANTIAGO DE CHILE  
2023

**RESUMEN DE LA MEMORIA PARA OPTAR AL  
TÍTULO DE:** Ingeniero Civil Industrial  
**POR:** Brian Esteban Fleiderman Sasso  
**FECHA:** 2023  
**PROFESOR GUÍA:** Pablo Marín Vicuña

**PREDICCIÓN DE LA DEMANDA DE LAS SOLICITUDES DE  
INTERCONSULTAS DE ESPECIALIDADES MÉDICAS Y ODONTOLÓGICAS  
DEL SSMSO**

El Servicio de Salud Metropolitano Sur Oriente (SSMSO) se encarga de la articulación, gestión y desarrollo de la Red Asistencial del Sector Sur Oriente de la Región Metropolitana. La problemática que enfrenta la organización corresponde a la elevada cantidad de usuarios en espera de recibir atención de Consulta de Especialidad No GES. Estas esperas se generan porque el proceso de programación de los servicios que ofrece la organización no se adapta a la demanda futura de los mismos.

El objetivo que busca resolver la problemática corresponde al siguiente: Desarrollar un método matemático de proyección de demanda de las solicitudes de interconsultas de especialidades No GES, con pronósticos más certeros que la media móvil, para que estos sirvan como insumo del Proceso de Programación del SSMSO. Para cumplir con el objetivo se desarrollaron 6 métodos predictivos: Alisamiento Exponencial, XGBoost, LightGBM, Regresión de Poisson, Ensemble Method (ARIMA, TBATS, MLP y ELM) y Media Móvil.

El modelo XGBoost obtiene el mejor rendimiento en el 92,06% (58/63) de las especialidades modeladas. En las especialidades en general alcanza un MAPE promedio de 15,21% y una desviación estándar del MAPE de 5,21%. Para las especialidades con bajas solicitudes (media mensual inferior o igual a 15 solicitudes de interconsultas en el conjunto de prueba), el modelo alcanza un MAE promedio de 1,65 unidades y una desviación estándar del MAE de 0,61 unidades.

El producto del presente trabajo permite que el SSMSO pueda anticipar cambios en el nivel de demanda de sus especialidades No GES, y adecuar oportunamente la oferta a las necesidades de la población. Habilitando así la detención del crecimiento de las Listas de Espera No GES. Aún más relevante es que facilitar una atención oportuna implica que en casos extremos se podría evitar la muerte de pacientes por falta de atención.

## **Dedicatoria**

Dedicado con cariño a los años de esfuerzo de mi madre y mi padre, quienes me apoyaron incondicionalmente en cada paso del camino e hicieron posible que el camino existiera.

En segundo lugar se lo dedico a amigos y amigas que hice en el trayecto, que con su alegría y excelente compañía hicieron que todo fuera más fácil.

## **Agradecimientos**

Agradecimientos especiales al Ingeniero Sr. René Lagos, a la Doctora Sra. Mariola Mestanza y al Ingeniero Sr. Rodrigo Guerrero de la Unidad de Salud Digital del SSMSO, quienes apoyaron y contribuyeron en cada tarea del presente trabajo.

También agradezco a los Profesores Guía, Co-guía, Profesor Integrante y a quienes me ayudaron a realizar el trabajo mediante todos sus comentarios y sugerencias, especialmente agradezco a la infinita paciencia que me regalaron.

## Tabla de Contenido

<b>1. INTRODUCCIÓN .....</b>	<b>1</b>
<b>2. PROBLEMA .....</b>	<b>2</b>
<b>3. JUSTIFICACIÓN .....</b>	<b>4</b>
<b>4. OBJETIVOS .....</b>	<b>5</b>
4.1. Objetivo General .....	5
4.2. Objetivos Específicos .....	5
<b>5. ALCANCE .....</b>	<b>5</b>
<b>6. RESULTADOS ESPERADOS.....</b>	<b>6</b>
<b>7. ESTADO DEL ARTE.....</b>	<b>6</b>
<b>8. MARCO CONCEPTUAL .....</b>	<b>7</b>
8.1. Modelos.....	8
8.1.1. Alisamiento Exponencial.....	8
8.1.2. Extreme Gradient Boosting (XGBoost).....	8
8.1.3. Light Gradient Boosting Machine (LightGBM).....	8
8.1.4. Ensemble Method .....	9
8.1.5. Media Móvil.....	10
8.1.6. Regresión de Poisson.....	11
8.2. Métricas de error .....	11
8.2.1. Mean Absolute Percentage Error (MAPE).....	11
8.2.2. Mean Absolute Error (MAE) .....	12
<b>9. METODOLOGÍA.....</b>	<b>12</b>
9.1. Entendimiento del Negocio.....	13
9.2. Entendimiento y Preparación de los Datos.....	13
9.3. Modelamiento .....	14
9.4. Evaluación .....	15
9.5. Despliegue.....	15
<b>10. DESARROLLO METODOLÓGICO.....</b>	<b>16</b>
10.1. Entendimiento del Negocio .....	16
10.1.1. Servicios del SSMSO .....	16
10.1.2. Definición de solicitud de interconsulta, centros de origen y destino .....	17
10.1.3. Centros de destino principales del SSMSO .....	17
10.1.4. Proceso vinculado a la problemática.....	17

10.2.	Entendimiento y Preparación de los Datos .....	19
10.2.1.	Selección.....	19
10.2.2.	Preprocesamiento.....	26
10.3.	Modelamiento .....	30
10.3.1.	Creación de los conjuntos de entrenamiento y de prueba .....	31
10.3.2.	Selección de centros de destino y especialidades a modelar .....	32
10.3.3.	Agrupación de especialidades a modelar.....	34
10.4.	Resultados .....	41
10.4.1.	Especialidades en general .....	42
10.4.2.	Especialidades con bajas solicitudes.....	50
10.5.	Despliegue .....	51
10.5.1.	Scripts de proyecciones .....	52
10.5.2.	Script de optimización de hiperparámetros .....	53
10.5.3.	Plan de Implementación .....	53
10.6.	Estrategias para la toma de decisiones .....	54
10.6.1.	Estrategias.....	54
10.6.2.	Recomendaciones complementarias .....	58
<b>11.</b>	<b>CONCLUSIONES .....</b>	<b>59</b>
<b>12.</b>	<b>DISCUSIÓN DE RESULTADOS .....</b>	<b>62</b>
<b>13.</b>	<b>RECOMENDACIONES A FUTURO.....</b>	<b>62</b>
<b>14.</b>	<b>GLOSARIO.....</b>	<b>63</b>
<b>15.</b>	<b>BIBLIOGRAFÍA.....</b>	<b>64</b>
<b>16.</b>	<b>ANEXOS .....</b>	<b>72</b>

## Índice de tablas

Tabla 1: <i>Tabla de variables disponibles en el consolidado de datos de la base de datos SIGTE</i> .....	27
Tabla 2: <i>Tabla de la cantidad de observaciones de las 10 especialidades No GES con más observaciones desde enero de 2017 a junio de 2022</i> .....	29
Tabla 3: <i>Cantidad de observaciones en los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022</i> .....	29
Tabla 4: <i>Cantidad de observaciones en los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022, después de agrupar las solicitudes por fecha</i> .....	30
Tabla 5: <i>Cantidad de observaciones en el conjunto de entrenamiento y de prueba de los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022</i> .....	32
Tabla 6: <i>Especialidades estacionarias de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones</i> .....	34
Tabla 7: <i>Especialidades con tendencia de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones</i> .....	36
Tabla 8: <i>Especialidades estacionales de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones</i> .....	37
Tabla 9: <i>Especialidades estacionales con tendencia de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones</i> .....	38
Tabla 10: <i>Especialidades con bajas solicitudes, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones</i> .....	40
Tabla 11: <i>Resultados de la métrica MAPE obtenida por los métodos predictivos en las proyecciones, en las especialidades estacionarias de las especialidades en general</i> .....	43
Tabla 12: <i>Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionarias de las especialidades en general</i> .....	44
Tabla 13: <i>Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionarias de las especialidades en general</i> .....	45
Tabla 14: <i>Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades con tendencia de las especialidades en general</i> .....	45
Tabla 15: <i>Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades con tendencia de las especialidades en general</i> .....	47
Tabla 16: <i>Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionales de las especialidades en general</i> .....	47
Tabla 17: <i>Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionales de las especialidades en general</i> .....	48
Tabla 18: <i>Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionales con tendencia de las especialidades en general</i> .....	49
Tabla 19: <i>Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionales con tendencia de las especialidades en general</i> .....	50

Tabla 20: Resumen de la métrica de error MAE que obtienen los métodos predictivos en las especialidades con bajas solicitudes .....50

## Índice de ilustraciones

Figura 1: <i>Lista de espera de Consulta de Especialidad No GES del SSMSO desde agosto de 2020 a noviembre de 2022</i> .....	3
Figura 2: <i>Metodología CRISP-DM</i> .....	13
Figura 3: <i>Proceso de Programación del SSMSO y Proyección de la Demanda</i> .....	17
Figura 4: <i>Gráfico de la distribución de las solicitudes de interconsulta por centro de destino</i> .....	20
Figura 5: <i>Histograma de la cantidad de solicitudes de interconsultas de cada especialidad en el consolidado SIGTE</i> .....	22
Figura 6: <i>Gráfico de la Evolución de las Solicitudes de Interconsultas de Cardiología del Hospital Dra. Eloísa Díaz 2016-2022</i> .....	23
Figura 7: <i>Gráfico de la Evolución de las Solicitudes de Interconsultas de Oftalmología del Hospital Padre Hurtado 2017-2022</i> .....	24
Figura 8: <i>Evolución Solicitudes de Interconsultas de Enfermedades Respiratorias del Adulto por trimestres desde el año 2016 al 2019 de los centros de destino con más solicitudes</i> .....	25
Figura 9: <i>Diagrama de los pasos de la Preparación de los Datos</i> .....	26
Figura 10: <i>Diagrama de los pasos del Modelamiento</i> .....	31
Figura 11: <i>Histograma de la cantidad de observaciones de cada especialidad en el conjunto de entrenamiento tras realizar principales pasos de la preparación de los datos</i> .....	33

## Índice de Fórmulas

Fórmula 1: <i>Ecuación de la métrica de error Mean Absolute Percentage Error (MAPE)</i>	11
Fórmula 2: <i>Ecuación de la métrica de error Mean Absolute Error (MAE)</i> .....	12

## 1. INTRODUCCIÓN

El Servicio de Salud Metropolitano Sur Oriente (SSMSO) se encarga de la articulación, gestión y desarrollo de la Red Asistencial del Sector Sur Oriente de la Región Metropolitana [1]. Esta última se conforma por 7 comunas [2] y entre ellas se encuentran Puente Alto y La Florida, la comuna más poblada y la cuarta más poblada de Chile, respectivamente [3].

Las Consultas de Especialidad No GES corresponde a uno de los servicios que ofrece la red del SSMSO, el acceso a este servicio en la red tiene una lista de espera asociada y esta última se encuentra entre las 5 más abultadas del país [4]. Lo anterior resulta un hecho esperable dada la magnitud de la red en cuestión y la situación a nivel nacional respecto a las listas de espera.

Las listas de espera son gestionadas por los Servicios de Salud públicos en pos de su reducción. Sin embargo, aun siendo gestionadas por estos organismos y corresponder a una problemática alarmante que data de años atrás [5], en la actualidad existe una elevada cantidad de usuarios en espera de acceder a una Consulta de Especialidad No GES a nivel nacional.

Las listas de espera de por sí ya son un hecho grave para la salud del país, no obstante, aún más dramático es la cantidad de usuarios que fallecen en lista de espera de Consultas de Especialidad No GES. El último registro público a nivel nacional indica que 18.962 usuarios fallecieron esperando concretar su interconsulta, entre enero a junio de 2021 [6]. De la cifra en cuestión, 1.558 usuarios fallecieron estando en la lista de espera del Servicio de Salud Metropolitano Sur Oriente (SSMSO), la organización vinculada al presente trabajo.

Asimismo el tiempo de espera promedio en las listas de espera a nivel nacional, para acceder a una consulta nueva de especialidad (primera consulta) corresponde a 455 días. En el caso particular del SSMSO la cifra asciende a un tiempo de espera promedio de 475 días. La información anterior corresponde al último registro público en la materia, este considera los datos disponibles hasta el 30 de septiembre de 2022 [7].

La causa principal de la problemática mencionada, corresponde al hecho que el proceso de programación de los servicios del SSMSO no considera la demanda futura de los

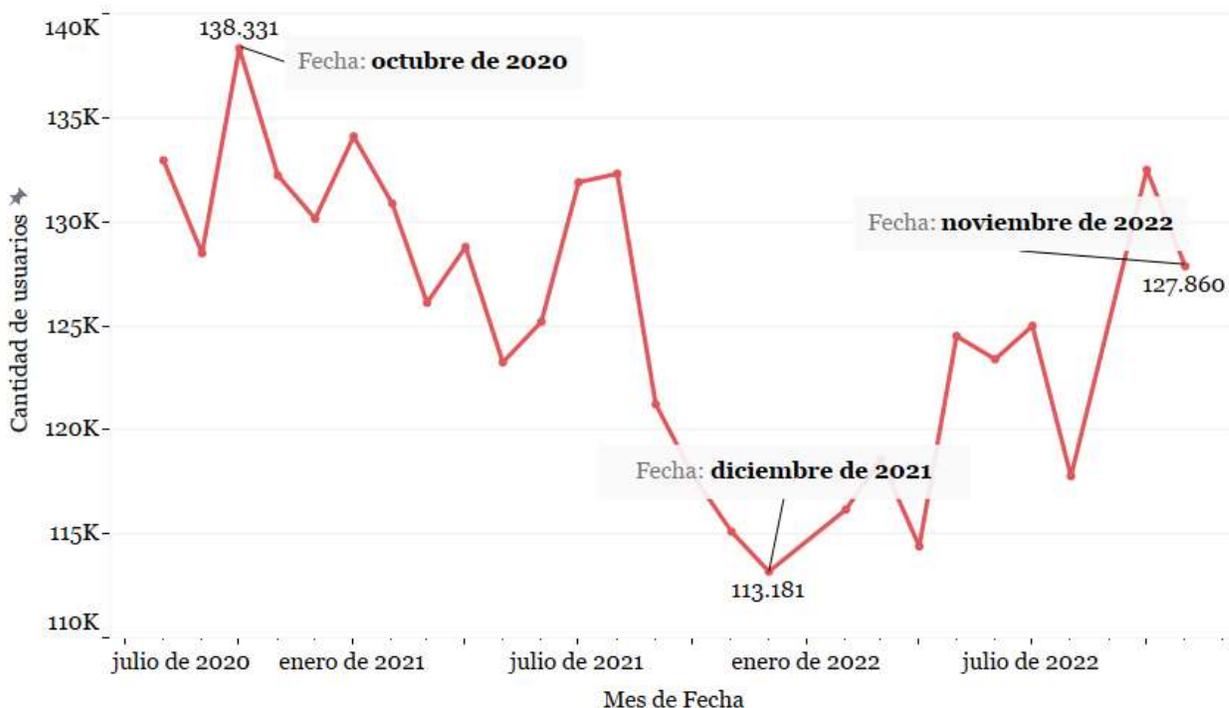
mismos. En otras palabras, en la actualidad el Proceso de Programación se puede clasificar como un proceso ineficiente. De esta forma, las listas de espera de las Consultas de Especialidad No GES son una grave consecuencia de esta situación.

El foco de interés del presente trabajo es abordar la causa principal que se identifica de la problemática, en específico busca desarrollar un método matemático de proyección de demanda de las solicitudes de interconsultas de especialidades No GES. Lo anterior para lograr optimizar periódicamente el Proceso de Programación del SSMSO, este se encarga a grandes rasgos de cuantificar la oferta de los servicios para cada establecimiento de la Red.

## **2. PROBLEMA**

El presente trabajo aborda una problemática que presenta el SSMSO. El problema corresponde a la elevada cantidad de usuarios en espera de acceder a la primera consulta de especialidad No GES, debido a que el proceso de programación de los servicios que ofrece el SSMSO no se adapta a la demanda futura de los mismos. La *Figura 1* presenta la evolución de la Lista de espera de este tipo de consultas desde agosto de 2020 a noviembre de 2022, particularmente este último registro indica que a la fecha existen 127.860 usuarios en espera de recibir atención [8].

**Figura 1:** Lista de espera de Consulta de Especialidad No GES del SSMSO desde agosto de 2020 a noviembre de 2022



Fuente: Elaborado por el autor utilizando los datos públicos disponibles de la Unidad de Salud Digital SSMSO.

El trabajo que se realiza se enfoca particularmente en desarrollar una solución, que permita estimar las solicitudes de interconsultas de especialidades médicas y odontológicas No GES. Estas últimas por simplicidad se denominan en el documento como especialidades. Mediante la solución se busca que el Proceso de Programación del SSMSO incorpore la componente de la demanda de este tipo de consultas, para que se generen estrategias de gestión que permitan adaptar la oferta a la demanda proyectada.

La literatura también presenta razones que justifican el uso de métodos de estimación de la demanda. En ella se afirma que el personal de producción y operaciones utiliza los pronósticos para tomar decisiones periódicas que comprenden la selección de procesos, la planificación de las capacidades y la distribución de las instalaciones. En síntesis los pronósticos apoyan la toma de decisiones acerca de la planificación de la producción, la programación y el inventario [9].

### 3. JUSTIFICACIÓN

La principal justificación del problema se vincula a la relación entre oferta y demanda, en particular hay dos escenarios perjudiciales posibles. El primero ocurre si la demanda de las interconsultas de especialidades médicas u odontológicas No GES supera a la oferta de este tipo de consultas. El segundo corresponde al caso contrario, es decir, si la oferta de este tipo de consultas es superior a la demanda.

El primer caso en el cual la demanda supera a la oferta, provocaría que pacientes que necesitan atenderse queden sin poder recibir una atención oportuna. De esta forma se estarían generando listas de esperas del servicio que se busca acceder, esto aumentaría la cantidad de pacientes en espera de recibir atención de especialidad No GES y el tiempo de espera de la misma. Por último y más importante, es el hecho que una mayor espera de los pacientes para recibir atención influye en un aumento de la mortalidad de las personas [10].

El segundo caso en el cual la oferta supera a la demanda, provocaría que hospitales incurran en gastos operacionales de recursos que no se van a utilizar. En esta situación es posible estimar en \$460.000 los gastos diarios, por cada médico especialista que no realice ninguna atención ni preste ningún tipo de servicio en ese día. La estimación se calcula bajo los supuesto de una jornada laboral de 9 horas y que el sueldo promedio de un médico especialista con 45 horas semanales alcanza los \$2.300.000 (\$51.111,11/hora) [11], es oportuno mencionar que la estimación no considera el gasto de las instalaciones.

Respecto a la aproximación se puede profundizar más. Los gastos al día que incurre un hospital ascienden a \$4.600.000, si se consideran tan solo 10 especialistas que asistan a su trabajo y que no reciban pacientes ni brinden ningún tipo de servicio en ese día. Los gastos totales ascienden a \$202.400.000 en un solo año debido a servicios que no fueron prestados, bajo los supuestos que la situación descrita ocurra al menos 2 meses en un año y 22 días laborales cada mes.

La conclusión es que ambos escenarios son perjudiciales para la organización, y el escenario actual corresponde principalmente al caso de listas de espera abultadas. Desde estos puntos surge la necesidad urgente del SSMSO, de buscar alternativas para reducir al máximo las listas de espera de la red de atención que gestiona y en particular la de las especialidades No GES.

## **4. OBJETIVOS**

### **4.1. Objetivo General**

Desarrollar un método matemático de proyección de demanda de las solicitudes de interconsultas de especialidades No GES, con pronósticos más certeros que la media móvil, para que estos sirvan como insumo del Proceso de Programación del SSMSO.

### **4.2. Objetivos Específicos**

- Identificar variables disponibles que influyen en la demanda de solicitudes de interconsultas de especialidad.
- Desarrollar y evaluar métodos matemáticos de predicción de la demanda de solicitudes de interconsultas de cada especialidad médica y odontológica No GES.
- Desarrollar métodos matemáticos que permitan realizar proyecciones de forma periódica de la demanda de las solicitudes de interconsultas de las especialidades No GES, para cada centro de destino del SSMSO.
- Aplicar el método matemático a la organización para la toma de decisiones, en el marco del Proceso de Programación del SSMSO.

## **5. ALCANCE**

Respecto al alcance del presente trabajo, se afirma que esta memoria comprende exclusivamente el problema de predicción de la demanda mensual de las solicitudes de interconsultas de especialidades No GES. Lo anterior, para optimizar la programación de la oferta de estas consultas en el SSMSO.

El alcance excluye la estimación de la demanda de especialidades GES y otras aristas de la demanda que también son parte del Proceso de Programación. En específico no se aborda las demandas de procedimientos, de cirugías, de exámenes, de atenciones de especialidades médicas u odontológicas de control (atenciones de pacientes en tratamiento), así como tampoco la demanda de atenciones no médicas.

## **6. RESULTADOS ESPERADOS**

En cuanto a los resultados esperados, se afirma que existen principalmente cuatro resultados del trabajo. A continuación se presentan estos últimos:

- Identificación de las variables disponibles que influyen en la estimación de la demanda de las solicitudes de interconsultas de especialidades No GES.
- Métodos matemáticos que permiten estimar la demanda mensual de las solicitudes de interconsultas de cada especialidad No GES y sus respectivas métricas de error.
- Automatización de los resultados del punto 2, para incorporarlos en las programaciones periódicas de los servicios de cada centro de destino del SSMSO.
- Generar sugerencias de estrategias para la toma de decisiones, en el marco del Proceso de Programación del SSMSO.

## **7. ESTADO DEL ARTE**

Los métodos predictivos XGBoost, LightGBM y los Ensemble Method, se consideran parte del Estado del Arte del mundo de los modelos predictivos de series de tiempo. Evidencia de lo anterior es la presencia de estos métodos en los primeros lugares de las competencias internacionales de esta área, así como premios asociados al uso de estos métodos.

El modelo ganador en la quinta edición de las reconocidas internacionalmente Competencias Makridakis “M5 Accuracy” (2020), corresponde al modelo LightGBM el

cual es similar al modelo XGBoost [12]. Las Competencias Makridakis han influenciado el campo de las proyecciones de series de tiempo desde 1982, y se enfocan en encontrar los modelos capaces de generar las proyecciones más precisas [13]. Basándose en lo anterior, se concluye que estos modelos son parte del Estado del Arte de los métodos predictivos de series de tiempo.

Los Ensemble Method forman parte de un proyecto que resultó ganador del Premio Franz Edelman 2022, el cual fue desarrollado por académicos de la FCFM e investigadores del ISCI [14]. Los premios Franz Edelman distinguen entre otras cosas, las aplicaciones de analítica avanzada más destacadas y de mayor impacto en el mundo [15]. El método en cuestión involucra los modelos ARIMAX, TBATS, MLP, ELM y GMDH, para el pronóstico a corto plazo de las camas UCI (series de tiempo) en el contexto de la pandemia COVID-19 en Chile [16].

Los Ensemble Method también son recomendados en otras investigaciones que buscan analizar los métodos que constituyen el Estado del Arte [17] [18]. Esto último vuelve a confirmar la relevancia actual de los Ensemble Methods. Basándose en los puntos anteriores, se concluye que los Ensemble Method también constituyen el Estado del Arte de los métodos predictivos de series de tiempo.

Es preciso notar que modelos clásicos como el Alisamiento Exponencial no se consideran hoy en día parte del Estado del Arte, a pesar de que sí lo hicieron en su debido momento. Evidencia de lo anterior es que los modelos clásicos no fueron superados hasta la cuarta edición de las competencias internacionales Makridakis (M4) [19], por lo que se consideran de igual forma para el trabajo desarrollado.

La conclusión es que los métodos mencionados, así como otros modelos más clásicos representan una herramienta poderosa y oportuna para el desarrollo del tema de memoria a trabajar. En la sección siguiente se describen todos los modelos utilizados, y particularmente también los que destacan en el Estado del Arte.

## **8. MARCO CONCEPTUAL**

El ámbito de la Ingeniería Civil Industrial que enmarca el presente trabajo corresponde a la gestión de operaciones. En específico se relaciona a la optimización de un proceso. El propósito de la optimización en cuestión es principalmente la maximización de la

eficiencia, lo que se logra en este caso mediante el uso de métodos matemáticos de predicción de la demanda.

## **8.1. Modelos**

Los métodos predictivos que se emplean son Alisamiento Exponencial, XGBoost, LightGBM, Ensemble Method, Regresión de Poisson y Media Móvil. Particularmente el Ensemble Method que se utiliza, involucra a los modelos ARIMA, TBATS, MLP y ELM. Es preciso señalar que los modelos que se utilizan corresponden a modelos de Machine Learning y modelos clásicos.

### **8.1.1. Alisamiento Exponencial**

Alisamiento Exponencial es un modelo que se emplea para generar pronósticos de series de tiempo, en el que se utiliza la demanda histórica como insumo para proyectar la serie. El cálculo se realiza específicamente con las ponderaciones de las observaciones pasadas. Un punto favorable de este método clásico es que es más fácil de implementar y utiliza una cantidad baja de recursos computacionales, además es capaz de modelar series de tiempo estacionarias (Alisamiento Exponencial Simple), con tendencia (Alisamiento Exponencial Doble) y/o con estacionalidad (Alisamiento Exponencial Triple) [20].

### **8.1.2. Extreme Gradient Boosting (XGBoost)**

Extreme Gradient Boosting (XGBoost) es un modelo basado en Gradient Boost Trees (conjunto de Árboles de Decisión), el cual también involucra al Stochastic Gradient Descent (SGD). Este último, es un método para optimizar una función objetivo de forma iterativa. En definitiva corresponde a un modelo que intenta predecir una variable objetivo, mediante la combinación de las estimaciones de otros modelos menos sofisticados (Árboles de Decisión) [21].

### **8.1.3. Light Gradient Boosting Machine (LightGBM)**

LightGBM es un modelo de Machine Learning que se basa en Gradient Boost Trees (conjunto de Árboles de Decisión), asemejándose así al modelo XGBoost.

Particularmente se diferencia de este modelo al ser capaz de alcanzar mayor precisión y una velocidad de entrenamiento mayor, adicionalmente utiliza menos memoria. LightGBM se emplea para tareas de clasificación y de regresión [22].

#### **8.1.4. Ensemble Method**

Ensemble Method es un método predictivo que combina distintos pronósticos de diversos modelos, para luego concluir en un pronóstico más preciso [23]. Particularmente en el presente trabajo, el Ensemble Method utiliza los modelos ARIMA, TBATS, MLP y ELM. En cuanto a la generación de proyecciones se emplean los métodos Conditional Mean y Trimmed Mean, de manera posterior se selecciona el método que obtiene los mejores resultados.

Conditional Mean o Conditional Expectation, hace referencia al cálculo de la media luego de modificar las proyecciones bajo una condición [24]. En el caso del presente trabajo, la condición consiste en sustracciones del mínimo y el máximo de cada observación de las proyecciones. Mientras que el Trimmed Mean o Truncated Mean, es la media que elimina un porcentaje de los outliers (observaciones extremas y atípicas) que podrían afectar el cálculo regular [25].

##### **8.1.4.1. Autoregressive Integrated Moving Average (ARIMA)**

ARIMA es un modelo autorregresivo (regresión de una variable basándose en la misma variable en un tiempo pasado) con medias móviles (la media de distintos periodos) y con un componente que permite analizar la serie de tiempo como si fuera estacionaria. En definitiva corresponde a un modelo predictivo que realiza regresiones a los datos, basándose principalmente en sus valores y errores previos [26].

##### **8.1.4.2. Trigonometric Seasonality – Box-Cox Transformation – ARMA errors – Trend – Seasonal Components (TBATS)**

TBATS es un modelo que utiliza a nivel general la normalización Box-Cox Transformation, los errores del modelo autorregresivo ARMA, la tendencia del fenómeno, y componentes estacionales trigonométricas. Box-Cox Transformation corresponde a un método de normalización que hace más eficientes y precisos los

cálculos, el modelo ARMA es un modelo autorregresivo más básico que ARIMA. Por último, las componentes trigonométricas corresponden a las funciones trigonométricas estacionales como el seno y el coseno [27].

#### **8.1.4.3. Multilayer Perceptron (MLP)**

MLP es un tipo de red neuronal artificial con 1 hasta 2 capas ocultas, el que también considera una capa de entrada y una capa de salida. Las capas ocultas se denominan de esta manera a raíz que contienen “neuronas” o unidades ocultas, el valor de cada unidad oculta es una función de las variables predictoras (variables independientes) [28]. Se diferencia de otras arquitecturas neuronales, principalmente en su número reducido de capas ocultas [29].

#### **8.1.4.4. Extreme Learning Machine (ELM)**

ELM es básicamente una red neuronal artificial que aprende mucho más rápido que el resto de redes neuronales, dado que simplifica el método que tiene la red para aprender. Particularmente el modelo ELM selecciona aleatoriamente nodos de la capa oculta y determina sus pesos de forma analítica, lo anterior acelera significativamente los tiempos que toma una red neuronal en obtener un resultado [30].

#### **8.1.5. Media Móvil**

La Media Móvil es un método estadístico que se emplea generalmente para proyectar tendencias a largo plazo, funciona a través del cálculo de la media de un conjunto de números en un rango y el posterior desplazamiento de este rango. A pesar de su cálculo relativamente simple, puede estimar los valores futuros de las series de tiempo [31]. Las proyecciones del modelo obtiene mejores resultados en series de tiempo estacionarias, las que tienen características tales como una media y desviación estándar constantes [32].

### 8.1.6. Regresión de Poisson

La Regresión de Poisson es un modelo que involucra la Distribución de Poisson, distribución que se emplea para encontrar la probabilidad de que ocurran eventos dentro de un intervalo de tiempo dado. Lo anterior implica que este modelo se emplea para datos que sean conteos de eventos con una componente temporal, lo cual supone que el resultado debe ser estrictamente no negativo [33]. Esta última cualidad beneficia al modelo frente a otros modelos que sí consideran valores negativos en sus predicciones, lo que es contrario a la naturaleza del problema (las demandas de las solicitudes de interconsultas son valores enteros mayor o igual a cero).

## 8.2. Métricas de error

### 8.2.1. Mean Absolute Percentage Error (MAPE)

El Error Porcentual Absoluto Medio (MAPE por sus siglas en inglés) es una de las métricas de errores más populares para medir la precisión de las estimaciones, mide el tamaño del error (absoluto) en términos porcentuales [34]. La métrica de error MAPE es recomendada en la mayoría de la literatura, además de ser utilizada como la principal métrica en las anteriormente mencionadas Competencias M (Makridakis) [35]. Esta métrica de error se calcula como indica la *Fórmula 1*.

**Fórmula 1:** Ecuación de la métrica de error Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} * 100$$

Fuente: CodingProf. How to Calculate the Weighted Mean Absolute Percentage Error in R.

En la cual:

- $y_i$  corresponde al valor real de la observación (resultado esperado).
- $\hat{y}_i$  corresponde a la estimación del modelo.

- $n$  corresponde al número de observaciones.

### 8.2.2. Mean Absolute Error (MAE)

El Error Absoluto Medio (MAE por sus siglas en inglés) es una métrica de error empleada para evaluar modelos de regresión, en la que cada error corresponde al valor absoluto de la diferencia entre el valor real y el valor estimado. Para el cálculo de la métrica en cuestión se pondera todos los errores para obtener la media de los errores, de modo que el MAE indica el número promedio de unidades erradas por los modelos [36]. Esta métrica de error se calcula como indica la *Fórmula 2*.

**Fórmula 2:** Ecuación de la métrica de error Mean Absolute Error (MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Fuente: Towards Data Science. Time Series Forecast Error Metrics You Should Know.

En la cual:

- $y_i$  corresponde al valor real de la observación (resultado esperado).
- $\hat{y}_i$  corresponde a la estimación del modelo.
- $n$  corresponde al número de observaciones.

## 9. METODOLOGÍA

El desarrollo de esta sección corresponde al desglose de actividades que nacen a raíz de la aplicación y adaptación de la metodología CRIPS-DM, a la problemática que aborda el presente trabajo. La *Figura 2* muestra las etapas de esta metodología, cabe notar que estas son iterativas por lo que es posible volver desde etapas posteriores hacia etapas

previas. Se decide utilizar esta metodología dada la libertad que brinda para iterar sobre las etapas, así como su capacidad de adaptación a las necesidades de la organización [37].

**Figura 2:** Metodología CRISP-DM



Fuente: Adictos al trabajo. Metodología CRISP-DM.

### 9.1. Entendimiento del Negocio

El Entendimiento del Negocio se desarrolla principalmente mediante reuniones con el equipo de la Unidad de Salud Digital del SSMSO, logrando así determinar el proceso de la organización que se vincula a la problemática. Asimismo mediante estas reuniones se logra determinar los servicios que se ofrecen en la red del SSMSO, y el funcionamiento de las solicitudes de interconsulta de especialidades No GES.

### 9.2. Entendimiento y Preparación de los Datos

El Entendimiento y Preparación de los Datos se divide en dos grandes subsecciones la Selección y el Preprocesamiento. La Selección comienza con la determinación de la base de datos para la tarea predictiva, seguido por un análisis descriptivo de los datos que se

disponen, la caracterización de las series de tiempo de las solicitudes de interconsultas de especialidad No GES y por último una revisión de la calidad de los datos. Mientras que en la subsección Preprocesamiento se determinan las variables independientes y la variable objetivo que se utilizan, también se detallan los pasos que se realizan en la preparación de los datos.

El preprocesamiento que se realiza a los datos tiene como propósito que las series de tiempo a modelar sean exclusivas de una especialidad y centro particular. Para lograr esta tarea se comienza por seleccionar los datos por fecha, separarlos por especialidad, seleccionar y separar por centro de destino. Luego, se agrupan y se agregan las observaciones por fecha. Al terminar los pasos del preprocesamiento, se obtiene como resultado los subconjuntos de datos necesarios para continuar con el Modelamiento de la tarea predictiva.

### **9.3. Modelamiento**

El Modelamiento se realiza basándose en los subconjuntos de datos creados posteriores a la preparación de los datos, comienza por crear sus conjuntos de entrenamiento y de prueba para cada subconjunto. Entonces se realiza una selección de los centros de destino y las especialidades a modelar. Posteriormente se agrupan las especialidades en especialidades en general y especialidades con bajas solicitudes. Finalmente para las especialidades en general se realiza una nueva división, en dónde se agrupan basándose en su patrón de comportamiento (estacionario, con tendencia y/o con estacionalidad).

El Modelamiento también es la etapa en la que se definen los modelos a utilizar, de manera posterior se desarrolla cada uno de los modelos para cada especialidad modelada. En cuanto a la optimización de los modelos en su fase de entrenamiento, se afirma que se realiza para los modelos de Machine Learning que así lo permiten. Para las especialidades en general se realiza la optimización estableciendo la métrica de error MAPE como la métrica de evaluación, mientras que para las especialidades con bajas solicitudes se realiza mediante la métrica de error MAE.

Adicionalmente se realiza una optimización de los hiperparámetros de los modelos, es decir, la optimización de configuraciones de variables utilizadas en el entrenamiento del modelo con base en una métrica de error. En el caso de las especialidades en general se busca encontrar para cada modelo, la configuración de variables que minimice el MAPE.

Para las especialidades con bajas solicitudes se busca encontrar análogamente la configuración que minimice el MAE.

Con los pasos anteriores se logra obtener diversos modelos a evaluar para cada una de las especialidades. Es oportuno mencionar que para cada especialidad, el modelamiento se realiza respecto a las observaciones de un único centro de destino entre los disponible. El centro de destino a modelar en cada caso, corresponde al centro con más observaciones de la especialidad en el consolidado de datos original y en el conjunto prueba.

Respecto a la decisión de modelar solo uno de los centros de destino para cada especialidad, se afirma que posteriormente en la subsección *10.3.3. Agrupación de especialidades a modelar* se enseña un análisis de la representatividad de esta elección de centros. Es oportuno mencionar que a pesar de que el modelamiento se realice únicamente para un único centro de destino por especialidad, los scripts que se mencionan en la subsección 9.5. Despliegue se crean uno para cada centro de destino de los seleccionados *en la subsección 10.2.2.4 Selección y separación por centro de destino* (los principales centros de destinos del SSMSO).

#### **9.4. Evaluación**

La Evaluación es la etapa en la que se emplean métricas de error a las proyecciones realizadas por los modelos, con tal de contar con una medición de la precisión de los resultados. En el caso de las especialidades en general se emplea la métrica de error MAPE, y se busca encontrar el modelo que alcanza menor MAPE para cada especialidad. De forma análoga al caso anterior, las especialidades con un bajo nivel de solicitudes se evalúan mediante la métrica de error MAE.

#### **9.5. Despliegue**

Para la etapa de despliegue de los modelos en las operaciones del SSMSO, se realizan programas simples (scripts) que permitan estimar la demanda mensual futura de las solicitudes de interconsultas de cada especialidad. En particular se desarrolla un script por cada centro de destino, que permite realizar pronósticos a n-meses futuros según lo que indique el usuario. También se hace entrega a la organización un script para la optimización de los hiperparámetros de cada modelo.

La implementación propiamente tal de los scripts no se abarca en la presente memoria, sin embargo, sí se proponen los lineamientos principales para que esta se pueda realizar con los recursos de la organización. Estos lineamientos son un plan recomendado de la implementación, encargados de la ejecución de los scripts y herramientas tecnológicas vinculadas en cada tarea. Los lineamientos particulares así como la entrega de los scripts se acuerdan en conjunto con la organización para asegurar que efectivamente los scripts sean implementados.

## **10. DESARROLLO METODOLÓGICO**

### **10.1. Entendimiento del Negocio**

El desarrollo de este apartado comienza con un resumen de los servicios que ofrece el SSMSO, seguido por la definición y explicación del funcionamiento de las solicitudes de interconsultas. De igual forma se definen otros términos relevantes para el entendimiento del trabajo. De forma posterior se detalla el proceso de la organización que está vinculado al desarrollo del presente trabajo, con las implicancias que tienen los resultados que se obtienen para el proceso y la organización.

#### **10.1.1. Servicios del SSMSO**

La red asistencial del SSMSO ofrece servicios de la salud primaria, secundaria y terciaria. La primaria hace referencia a servicios de salud más básicos y se realizan en centros de baja complejidad (comúnmente consultorios). La secundaria hace referencia a atenciones de especialidad ambulatoria, las que se realizan en hospitales de mediana complejidad. La terciaria se caracteriza por la ejecución de intervenciones quirúrgicas y atenciones de mayor complejidad y de especialización que el resto de niveles, implicando por lo general hospitalización de los pacientes en hospitales de alta complejidad [38].

### 10.1.2. Definición de solicitud de interconsulta, centros de origen y destino

En cuanto a la definición de las solicitudes de interconsulta, se concluye que corresponden a las solicitudes que permiten derivar un paciente a una atención de especialidad médica u odontológica. En particular las interconsultas se originan en un centro del nivel primario o secundario de una red asistencial (centro de origen), y desde allí se deriva al paciente a un centro del nivel secundario o terciario de la misma red asistencial (centro de destino) [39]. Estas definiciones también se pueden encontrar en la sección 14. GLOSARIO.

### 10.1.3. Centros de destino principales del SSMSO

Respecto a los establecimientos de destino de las interconsultas se afirma que al año 2022, el SSMSO lleva a cabo sus interconsultas de especialidad en cuatro establecimientos. Los principales centros de destino corresponden al Hospital Dr. Sótero del Río, Hospital Dra. Eloísa Díaz, Hospital Padre Hurtado y en menor grado el CRS Hospital Provincia Cordillera [40]. Este último centro se busca convertir en un hospital de alta complejidad en los próximos años [41].

### 10.1.4. Proceso vinculado a la problemática

Respecto al proceso vinculado a la problemática, se afirma que este corresponde al Proceso de Programación. El proceso tiene como fin cuantificar el número de prestaciones anuales a ofertar por especialidad para cada establecimiento de la Red [42], para ello coordina los equipos de cada área médica de los centros del SSMSO. A modo de complementar la información se presenta la *Figura 3*, que representa las actuales etapas del Proceso de la Programación más una etapa nueva.

**Figura 3:** Proceso de Programación del SSMSO y Proyección de la Demanda



*Nota.* Los cuadros azules de la figura representan las etapas que en la actualidad contempla el Proceso de Programación, el cuadro naranja corresponde a una nueva etapa del proceso.

Fuente: Elaborado por el autor basándose en información entregada por la organización.

La figura resalta la inclusión de la etapa de “Proyección de Demanda” al Proceso de Programación del SSMSO. La etapa en cuestión hace referencia a las estimaciones de la demanda de todos los servicios del SSMSO, en particular el trabajo de memoria abarca las estimaciones de la demanda de las solicitudes de interconsultas de especialidad No GES. Estas últimas representan un input valioso para el resto del Proceso de Programación, esto considerando que el objetivo del proceso en el nivel secundario y terciario corresponde a:

“Optimizar la gestión de la Red Asistencial a través de la programación de la totalidad de horas disponibles en los establecimientos, con énfasis en la coordinación de ésta para satisfacer la demanda asistencial.” [43]

En síntesis, el Proceso de Programación define particularmente la cantidad de horas consulta de especialidad a ofertar. Cabe destacar que al incorporar proyecciones de las solicitudes de interconsulta por especialidad, permite que el SSMSO pueda anticiparse y realizar gestiones para aumentar su capacidad de atención de consultas de especialidad. Lo anterior es posible mediante las siguientes estrategias preestablecidas en las Orientaciones de la Programación del Ministerio de Salud (Minsal) [44]:

- Contratación de médicos u odontólogos especialistas que sean requeridos (full time o part time).
- Compra de servicios a otras instituciones de salud públicas o privadas.
- Realizar atenciones en horarios extendidos en los fines de semana.

## **10.2. Entendimiento y Preparación de los Datos**

El desarrollo del apartado comienza con la determinación de la base de datos útil para la tarea predictiva, posteriormente se exploran los datos y se seleccionan las variables independientes y la variable objetivo a trabajar. Lo anterior permite afirmar que en esta subsección se abarca el objetivo específico: *Identificar variables disponibles que influyen en la demanda de solicitudes de interconsultas de especialidad*, de la subsección 4.2 *Objetivos Específicos*. Por último se realiza una caracterización de las series de tiempo de las solicitudes de interconsultas de especialidades médicas y odontológicas No GES, adicionalmente se revisa la calidad de los datos.

### **10.2.1. Selección**

#### **10.2.1.1. Datos**

Los datos se obtuvieron del Sistema de Información para la Gestión de Tiempos de Espera (SIGTE), el repositorio de listas de espera oficial del Ministerio de Salud. Se obtuvieron cortes mensuales de la lista de espera y cortes trimestrales de egresos de listas de espera. La organización construyó un proceso de extracción, transformación y carga (ETL por sus siglas en inglés) [45] para poder almacenar, procesar y analizar mensualmente estos datos en el marco de la programación médica. Para esto la organización utilizó el lenguaje de programación Python y la librería Pandas.

El proceso de ETL que implementó la organización consta con las siguientes etapas y herramientas computacionales: 1) carga y decodificación de registros del SIGTE (python), 2) consolidación de solicitudes de interconsulta y almacenamiento en formato pickle (python), 3) carga en sistema de base de datos (python y MS SQL Server).

Luego, los datos que se utilizan para el modelamiento corresponden al consolidado histórico de la base de datos SIGTE, el que se genera como fue mencionado en los párrafos previos y fue entregado por la organización. Este consolidado almacena la cantidad de solicitudes de interconsultas de especialidades médicas y odontológicas No GES, los datos en sí corresponden a un archivo “.csv”. Estos datos se emplean para el resto del presente trabajo y corresponden a datos estructurados con 9 variables (6 categóricas y 3 numéricas), estas últimas se describen posteriormente en 10.2.2.1. *Variables independientes y objetivo*.

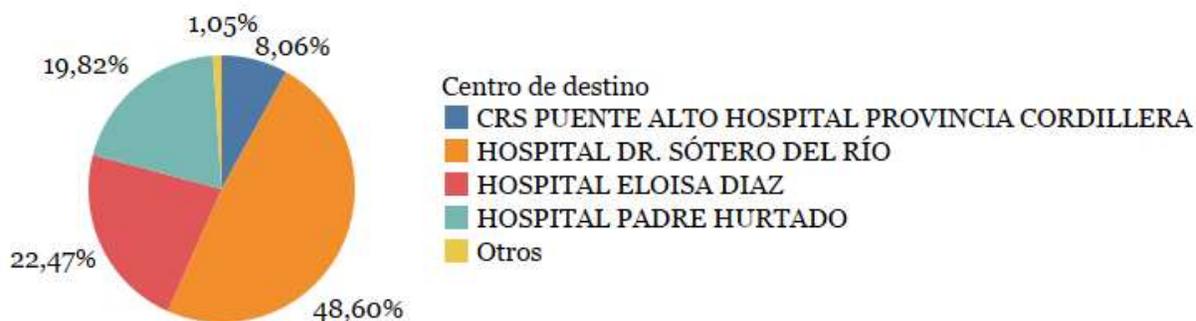
Es oportuno mencionar que para el modelamiento solo se emplean una selección de las observaciones del consolidado de datos SIGTE, particularmente se utilizan las observaciones desde Enero del 2017 a junio de 2022. Lo anterior se señala de igual forma en una subsección posterior 10.2.2.2. *Selección de fecha.*

#### 10.2.1.2. Análisis descriptivo de los datos

Respecto al análisis descriptivo de los datos utilizados, se afirma que el consolidado de datos considera 161.135 observaciones de granularidad mensual desde marzo de 2001 hasta julio de 2022. Sin embargo, los datos más completos recién comienzan en el año 2007. El resto del análisis descriptivo de los datos consiste en el detalle tanto de la distribución de las solicitudes por centro de destino, como de la cantidad de especialidades, así como de la cantidad de solicitudes por especialidad.

En cuanto a la distribución de las solicitudes por los principales centro de destino se presenta en la *Figura 4*, la cual grafica que el centro de destino que concentra la mayor cantidad de solicitudes de interconsultas corresponde al Hospital Dr. Sótero del Río. Por lo tanto, se puede inferir que la mayoría de las especialidades tienen a este establecimiento como el centro con la mayor cantidad de solicitudes de interconsultas.

**Figura 4:** Gráfico de la distribución de las solicitudes de interconsulta por centro de destino



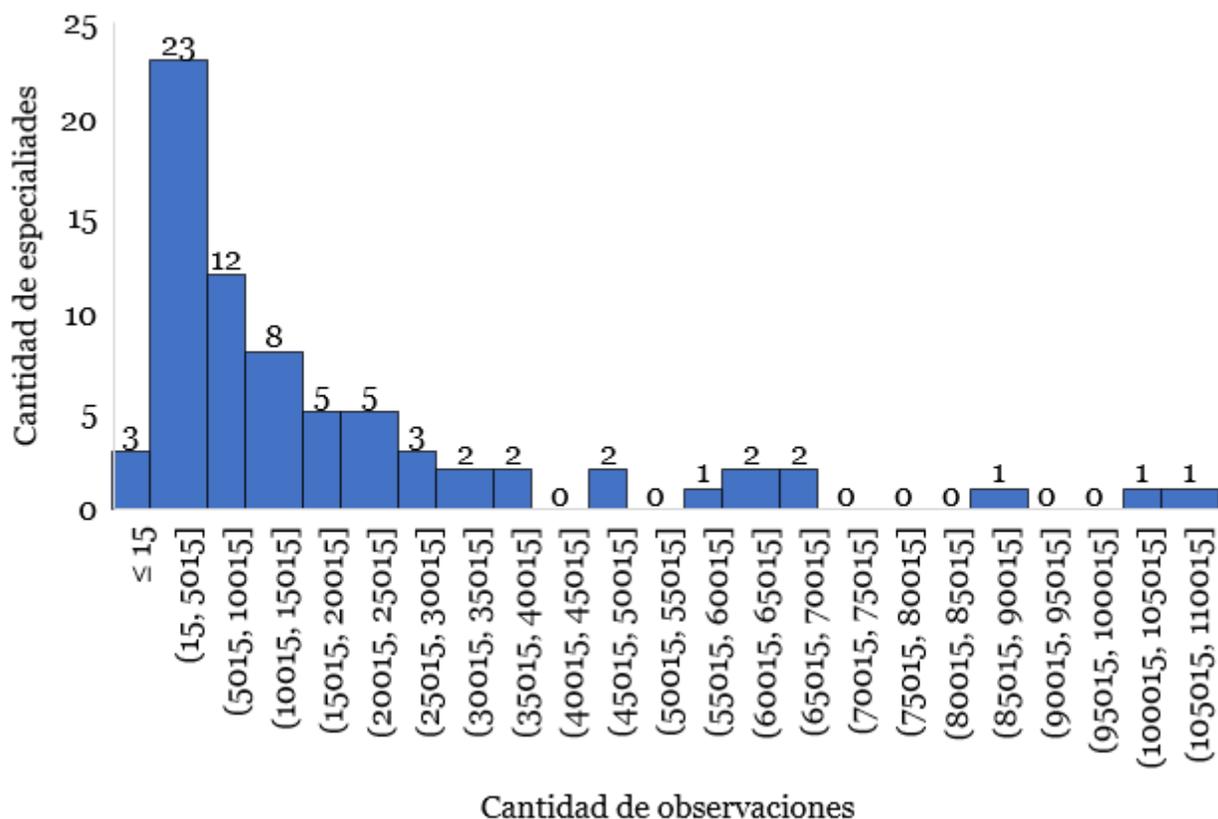
Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Concerniente a la cantidad de especialidades en el consolidado de datos se identifican 73 especialidades diferentes, de las cuales 60 son médicas y 13 son odontológicas. Al analizar la media de solicitudes de interconsultas del total de especialidades, se obtiene una cifra de 18.697 solicitudes en promedio ( $\mu$ ) y una desviación estándar ( $\sigma$ ) de 24.164,06 solicitudes. A raíz de la relación entre la desviación estándar y la media (coeficiente de variación), se concluye que las solicitudes tienen una dispersión alta y un alto grado de heterogeneidad [46].

La cantidad total de solicitudes de interconsulta en el consolidado de datos asciende a 1.364.861, lo anterior en el periodo que abarcan los datos (marzo de 2021 a julio de 2022). En cuanto la cantidad máxima y mínima de solicitudes de interconsulta registradas para una especialidad, se concluye que corresponden a 106.758 y 7 solicitudes, respectivamente.

La distribución de las solicitudes de interconsulta por especialidad se presenta en la *Figura 5*, la que permite concluir que la gran mayoría (76,71 %) de las especialidades cuenta con menos de 25.016 solicitudes en el periodo que abarca el consolidado de datos. Adicionalmente permite concluir que existen 3 especialidades con una cantidad igual o inferior a 15 solicitudes.

**Figura 5:** Histograma de la cantidad de solicitudes de interconsultas de cada especialidad en el consolidado SIGTE



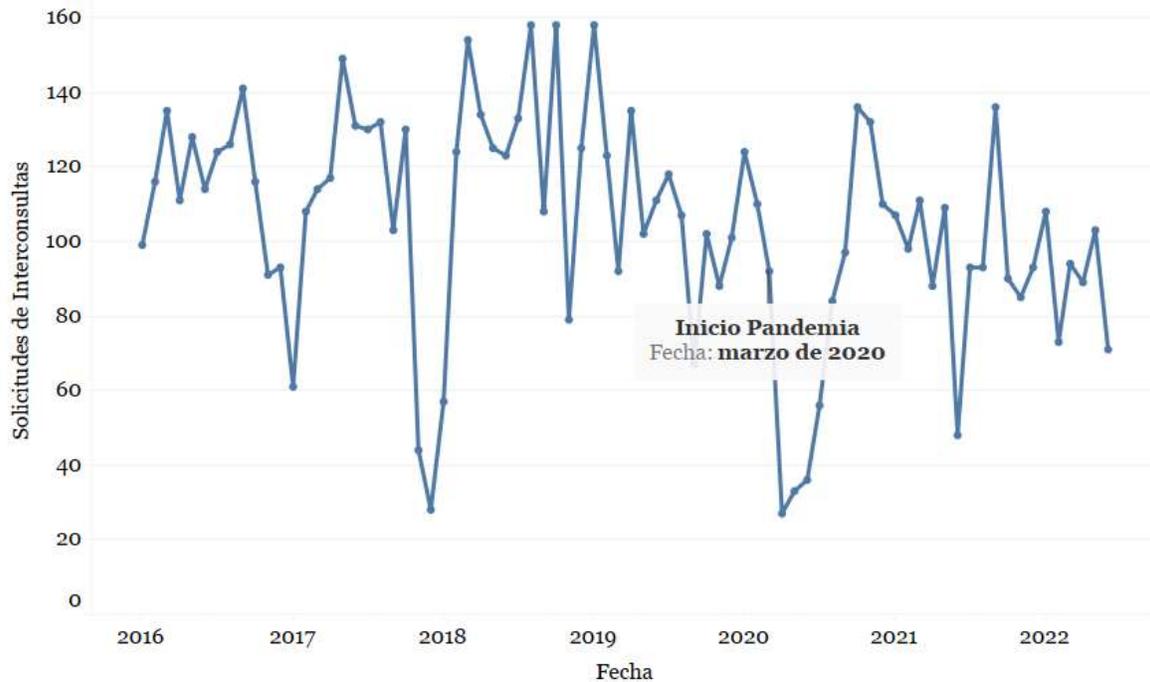
Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los métodos predictivos que se desarrollan requieren de un mínimo de observaciones para que puedan realizar proyecciones precisas, en consecuencia ciertas especialidades podrían ser descartadas del modelamiento por no contar con observaciones suficientes. Lo anterior basándose en la exploración de los datos que se realiza, particularmente la información que presenta la *Figura 5*. Es oportuno mencionar que las especialidades a modelar se definen posteriormente en la subsección 10.3.2. *Selección de centros de destino y especialidades a modelar*.

### 10.2.1.3. Caracterización de las series de tiempo de las especialidades

En cuanto a la caracterización de las series de tiempo de las especialidades, en la *Figura 6* se presenta la evolución de una de las series. La serie de tiempo de esta especialidad en particular se puede clasificar como una serie de tiempo estacionaria, dado que es posible notar que el nivel de solicitudes se mantiene a lo largo del tiempo. En definitiva, la serie de tiempo no presenta ni tendencia ni estacionalidad.

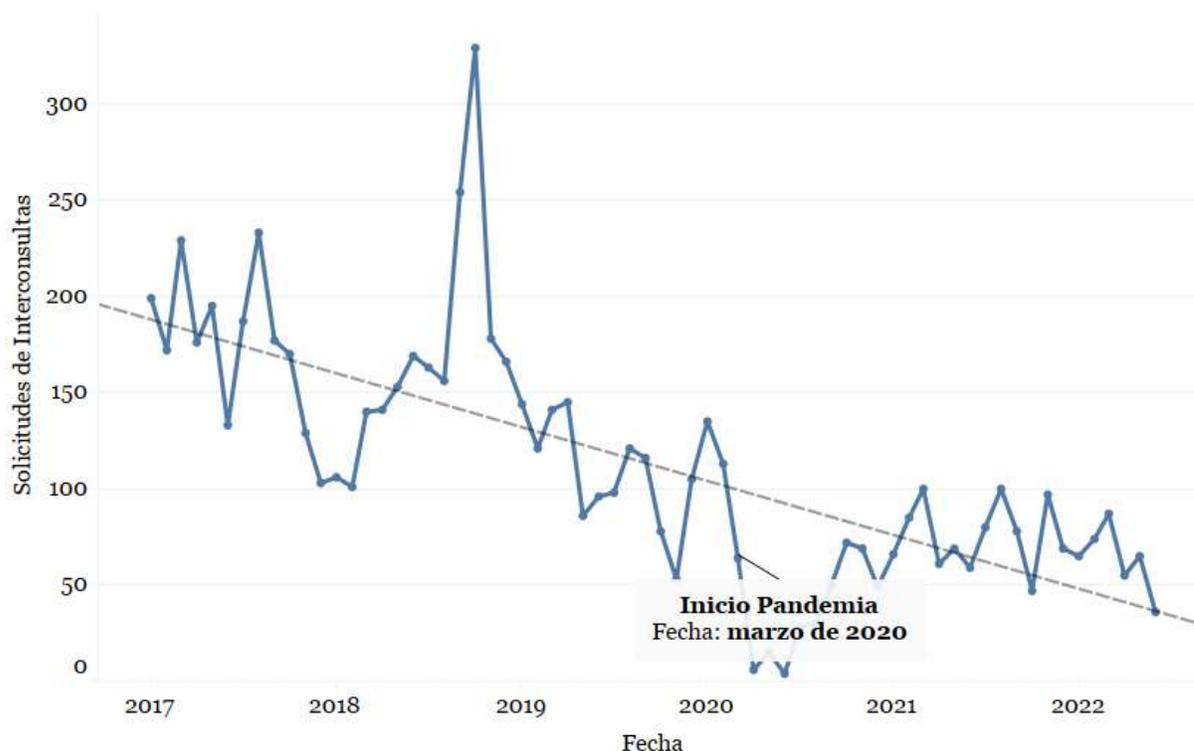
**Figura 6:** Gráfico de la Evolución de las Solicitudes de Interconsultas de Cardiología del Hospital Dra. Eloísa Díaz 2016-2022



Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Asimismo respecto a otro tipo de patrón de comportamiento, en la *Figura 7* se presenta una serie que se puede clasificar como una serie de tiempo con tendencia. En esta serie de tiempo se puede notar una tendencia a la baja, dado que el nivel de las solicitudes de interconsulta ha decrecido de forma sostenida en el tiempo. Lo anterior, es más evidente al observar la línea de tendencia (línea discontinua de color gris claro).

**Figura 7:** Gráfico de la Evolución de las Solicitudes de Interconsultas de Oftalmología del Hospital Padre Hurtado 2017-2022

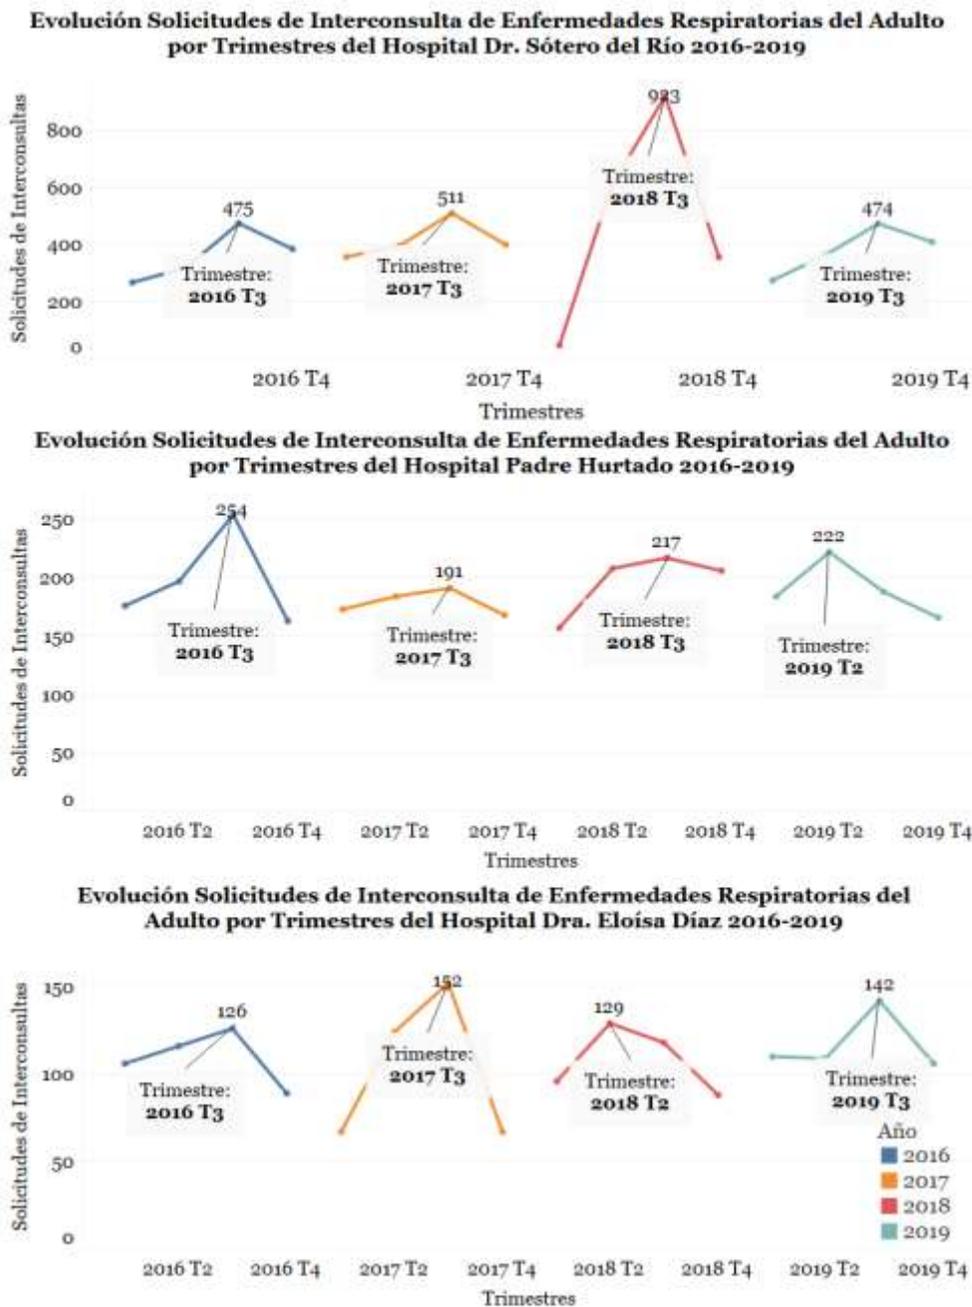


*Nota.* La línea discontinua de color gris claro corresponde a la línea de tendencia de la serie de tiempo.

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Por último, en la *Figura 8* se presenta una de las especialidades que se puede clasificar como una serie de tiempo con presencia de estacionalidad anual. Lo anterior se concluye a raíz que en la mayoría de los principales centros de destino, el tercer trimestre de cada año se alcanza el nivel más alto de solicitudes de interconsultas de esta especialidad. Es preciso enunciar que una serie de tiempo con estacionalidad también puede presentar tendencia.

**Figura 8:** Evolución Solicitudes de Interconsultas de Enfermedades Respiratorias del Adulto por trimestres desde el año 2016 al 2019 de los centros de destino con más solicitudes



Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Por consiguiente, es posible concluir que existen cuatro tipos de series de tiempo, estacionarias, con tendencia, con estacionalidad, y con tendencia y estacionalidad. Los

cuatro tipos de series cuentan con sus propias características las que influyen en la proyección de cada serie. El caso estacionario es el de más simple proyección [47], debido a que media del año anterior puede ser una proyección adecuada para el año siguiente.

#### 10.2.1.4. Calidad de los datos

Respecto a la exploración de la calidad de los datos disponibles se concluye que no se reportan problemas típicos de este ámbito, tales como la inexactitud, incompletitud o la inconsistencia en los datos. Con base en los puntos que se desarrollan en esta subsección, es posible concluir que es factible realizar el modelamiento de la demanda de las solicitudes de interconsultas de especialidades No GES. Lo anterior con tal de cumplir el objetivo del presente trabajo.

#### 10.2.2. Preprocesamiento

El desarrollo de esta etapa tiene como propósito que las series de tiempo a modelar sean exclusivas de una especialidad y centro particular. Al terminar los pasos del Preprocesamiento (o Preparación de los Datos), se obtiene como resultado los subconjuntos de datos necesarios para continuar con el Modelamiento de la tarea predictiva. La *Figura 9* presenta un diagrama que ilustra los pasos de la Preparación de los Datos.

**Figura 9:** Diagrama de los pasos de la Preparación de los Datos



Fuente: Elaborado por el autor.

### 10.2.2.1. Variables independientes y objetivo

Respecto a las variables explicativas o variables independientes que se utilizan y la variable objetivo de la problemática (variable a estimar), se afirma que las variables independientes corresponden exclusivamente al año y al mes. Mientras que la variable objetivo corresponde al total de solicitudes de interconsultas de cada especialidad, que se derivan mensualmente a un centro de destino. Esta variable se construye como se explica en las subsecciones siguientes (10.2.2.2 a 10.2.2.5).

La decisión de utilizar únicamente el año y el mes como variables independientes se decide a raíz del nivel de agregación de los datos, el que se obtiene con la preparación de los datos y genera que el resto de variables disponibles sean constantes. Es oportuno volver a mencionar que la preparación de los datos se enfoca en poder obtener proyecciones que correspondan a un centro, a una especialidad y a una fecha en específico. Lo anterior ayuda a entender como es el que resto de variables toman valores constantes. La *Tabla 1* resume las variables disponibles, sus descripciones y las variables independientes seleccionadas.

**Tabla 1:** *Tabla de variables disponibles en el consolidado de datos de la base de datos SIGTE*

<b>Nombre columna</b>	<b>Descripción</b>	<b>Tipo de variable</b>	<b>Se utiliza como variable independiente</b>
TIPO_PREST	Código del tipo de prestación	Categórica	No
TIPO_PREST_DESC	Tipo de prestación	Categórica	No
ESTAB_ORIG	Código del establecimiento de origen de la solicitud de interconsulta	Categórica	No
ESTAB_DEST	Código del establecimiento de destino de la solicitud de interconsulta	Categórica	No

<b>Nombre columna</b>	<b>Descripción</b>	<b>Tipo de variable</b>	<b>Se utiliza como variable independiente</b>
ESTAB_DEST_NOMBRE	Nombre del establecimiento de destino de la solicitud de interconsulta	Catagórica	No
PRESTA_MIN	Código de la especialidad de la solicitud de interconsulta	Catagórica	No
AÑO	Año en el que se deriva la solicitud de interconsulta	Numérica	Sí
MES	Mes en el que se deriva la solicitud de interconsulta	Numérica	Sí
N_ENTRADAS	Cantidad de solicitudes de interconsultas de derivadas desde un centro de origen a un centro de destino	Numérica	No

Fuente: Elaborado por el autor utilizando los datos del consolidado SIGTE.

#### **10.2.2.2. Selección de fecha**

En primer lugar, se realiza una selección de las observaciones del consolidado de datos SIGTE anteriores a enero de 2017. De esta forma, se aíslan los datos desde Enero del 2017 a junio de 2022. Luego, con este conjunto de datos se procede a realizar los siguientes pasos de la Preparación de los Datos.

#### **10.2.2.3. Separación por especialidad**

En segundo lugar, se separan los datos por cada especialidad logrando obtener un subconjunto de datos con su respectiva cantidad de observaciones. Es oportuno mencionar que cada una de estas observaciones corresponde a una oportunidad en la cual se generó una solicitud de interconsulta, desde enero de 2017 a junio de 2022. En la *Tabla 2* se presentan las 10 especialidades con más observaciones luego de realizar la selección por fecha y separación por especialidad.

**Tabla 2:** *Tabla de la cantidad de observaciones de las 10 especialidades No GES con más observaciones desde enero de 2017 a junio de 2022*

<b>Nombre Especialidad No GES</b>	<b>Cantidad de observaciones</b>
Oftalmología	4.147
Otorrinolaringología	3.683
Ginecología	3.578
Traumatología y Ortopedia	3.302
Dermatología	3.188
Cirugía General	3.084
Cirugía y Traumatología Buco Maxilofacial	3.068
Cardiología	2.969
Urología	2.890
Neurología Adulto	2.845

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

#### **10.2.2.4. Selección y separación por centro de destino**

En tercer lugar, para cada especialidad se seleccionan los datos de los principales centros de destino que reciben las solicitudes de interconsultas, excluyendo el resto de centros de destino que corresponden al nivel primario. Luego, se separan los datos para cada uno de los centros de destinos que antes se seleccionaron. Para ilustrar como funciona este paso en particular, se presenta la *Tabla 3* con la cantidad de observaciones de cada centro de destino seleccionado para una de las especialidades. Lo anterior después de realizar la selección de fecha, separación por especialidad y este último paso en particular.

**Tabla 3:** *Cantidad de observaciones en los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022*

<b>Hospital Dr. Sótero del Río</b>	<b>Hospital Padre Hurtado</b>	<b>Hospital Dra. Eloísa Díaz</b>	<b>CRS Hospital Provincia Cordillera</b>
1678	920	680	383

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### 10.2.2.5. Agrupación y agregación de observaciones por fecha

En cuarto lugar, se agrupan de manera temporal las solicitudes de interconsulta por fecha, específicamente se agrupan y se agregan las observaciones que coincidan en su fecha (mes y año). Esto se realiza para cada subconjunto que almacena las observaciones de un centro de destino y de una especialidad en particular. El paso descrito se realiza para lograr que cada observación represente el total de solicitudes de una especialidad que se derivaron en un mes, a uno de los centros de destino. De esta forma, si por ejemplo un centro de destino para una especialidad en particular recibió en un mes 20, 10 y 30 solicitudes de interconsulta de diferentes centros de orígenes, entonces ahora solo se tendría una sola observación con las 60 solicitudes registradas ese mes de esa especialidad en ese centro de destino.

El paso de esta subsección se ilustra en la *Tabla 4*, la que presenta la cantidad de observaciones de cada centro de destino de una de las especialidades. Lo anterior después de realizar la selección de fecha, separación por especialidad, selección y separación por centro de destino y el paso que se describe en esta subsección (agrupación y agregación de observaciones por fecha).

**Tabla 4:** *Cantidad de observaciones en los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022, después de agrupar las solicitudes por fecha*

<b>Hospital Dr. Sótero del Río</b>	<b>Hospital Padre Hurtado</b>	<b>Hospital Dra. Eloísa Díaz</b>	<b>CRS Hospital Provincia Cordillera</b>
66	66	66	64

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### 10.3. Modelamiento

La subsección de Modelamiento detalla los pasos que se realizan de manera posterior a la Preparación de Datos. Particularmente estos pasos permiten obtener como resultado los conjuntos de entrenamiento y de prueba de cada especialidad, la selección de los centros de destino y especialidades a modelar, así como los grupos definidos de estas especialidades. Al finalizar estos pasos se procede a realizar el entrenamiento de los

modelos, esto da paso a la subsección siguiente en la que se presentan los Resultados de los mismos. La *Figura 10* presenta un diagrama que ilustra los pasos del Modelamiento.

**Figura 10:** Diagrama de los pasos del Modelamiento



*Nota.* La data preprocesada de cada especialidad hace referencia a los subconjuntos de cada especialidad que se obtienen como producto de la Preparación de los Datos (Preprocesamiento).

Fuente: Elaborado por el autor.

### 10.3.1. Creación de los conjuntos de entrenamiento y de prueba

En primer lugar se crean los conjuntos de entrenamiento y de prueba para cada subconjunto generado en los pasos que se describen en la subsección 10.2.2. *Preprocesamiento*. Específicamente cada subconjunto almacena las solicitudes de interconsultas mensuales agrupadas por fecha, de un centro de destino y de una especialidad en particular. Por otro lado, la distribución de las observaciones en los conjuntos de entrenamiento corresponde a un 80% y en los conjuntos de prueba a un 20%.

El paso descrito se ilustra para una de las especialidades en la *Tabla 5*, esta presenta la cantidad de observaciones del conjunto de entrenamiento y de prueba de cada centro de destino de la especialidad. Lo anterior después de realizar los pasos de la subsección 10.2.2. *Preprocesamiento* y la creación de los conjuntos de entrenamiento y de prueba.

**Tabla 5:** Cantidad de observaciones en el conjunto de entrenamiento y de prueba de los principales centros de destino de la especialidad Oftalmología desde enero de 2017 a junio de 2022

Hospital Dr. Sótero del Río	Hospital Padre Hurtado	Hospital Dra. Eloísa Díaz	CRS Hospital Provincia Cordillera
Conjunto de entrenamiento			
52	52	52	51
Conjunto de prueba			
14	14	14	13

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### 10.3.2. Selección de centros de destino y especialidades a modelar

La presente subsección comienza con la definición de los centros de destino a modelar y posteriormente se abordan las especialidades a modelar. Respecto a los centros a modelar en cada caso, se define modelar el establecimiento con mayor número de observaciones de esa especialidad en la base de datos original y en el conjunto prueba (después de realizar todos los pasos previos). Se define de esta manera dado que se busca poder modelar la mayor cantidad de especialidades posibles.

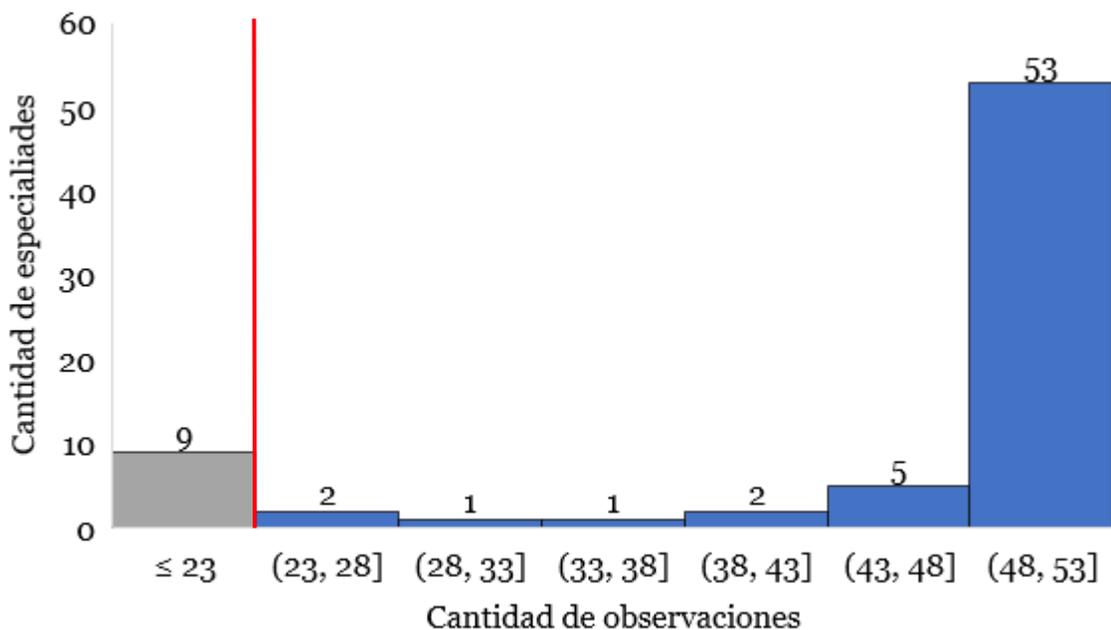
Los resultados de la selección de los establecimientos de destino a modelar para cada especialidad, se pueden observar en *Anexo A*. Mientras que un análisis de la representatividad de la elección de centro a modelar se presenta en la subsección siguiente 10.3.3. *Agrupación de especialidades a modelar*, particularmente se enseñan tablas con las cantidades de observaciones en el conjunto de entrenamiento del centro modelado, y el porcentaje que representan del total de observaciones (solo considerando los centros seleccionados en 10.2.2.4. *Selección y separación por centro de destino*). Adicionalmente al final de la subsección siguiente también se concluye respecto a la decisión de elegir los centros de destinos de la manera que se define.

Respecto a las especialidades que se modelan luego de haber realizado los pasos previos, se afirma que estas deben contar mínimamente con 24 observaciones en el conjunto de entrenamiento en el centro de destino modelado. Lo anterior para lograr que el modelamiento se lleve a cabo satisfactoriamente en los modelos que necesiten al menos dos ciclos completos de observaciones, considerando que cada ciclo completo

corresponde a 12 observaciones mensuales. Asimismo otra condición es que las especialidades estén vigentes, es decir, que cuenten con observaciones del último año disponible en el consolidado (2022).

La *Figura 11* presenta un histograma que muestra la cantidad de observaciones de cada especialidad en el conjunto de entrenamiento, lo anterior luego de realizar los pasos de las subsecciones previas (incluidos los pasos de 10.2.2. *Preprocesamiento*) y la selección del centro de destino a modelar para cada especialidad. El centro en cuestión corresponde al que se define al comienzo de la presente subsección.

**Figura 11:** Histograma de la cantidad de observaciones de cada especialidad en el conjunto de entrenamiento tras realizar principales pasos de la preparación de los datos



*Nota.* Las barras de color azul representan las especialidades que se modelan, la barra gris representa las especialidades que no se modelan por observaciones insuficientes. La línea roja delimita la cantidad mínima de 24 observaciones, definiendo la separación entre las especialidades que se modelan y las que no se modelan por observaciones insuficientes.

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

El criterio del mínimo de observaciones en el conjunto de prueba indicado previamente, define que existen 9 especialidades (Neonatología, Radioterapia Oncológica, Medicina Familiar del Niño, Cirugía de Mama, Enfermedades de Transmisión Sexual, Salud

Ocupacional, Cirugía Bucal, Operatoria Dental y Odontología Indiferenciado) que cuentan con menos de 24 observaciones en el conjunto de entrenamiento. Por lo tanto, no se modelan en el presente trabajo.

Respecto al criterio de considerar tan solo especialidades que se encuentren vigentes, se concluye que existe 1 especialidad (Infectología Pediátrica) que no cuenta con observaciones del año 2022. Por ende, tampoco se modela en el presente trabajo. A modo de resumen, de las 73 especialidades originales se modelan exclusivamente un total de 63 especialidades distintas.

### 10.3.3. Agrupación de especialidades a modelar

Por último, se realiza una agrupación de las especialidades. Para realizar esta agrupación se dividen en dos grandes grupos, especialidades en general y especialidades con bajas solicitudes mensuales. Luego, para las especialidades en general se agrupan nuevamente basándose en su patrón de comportamiento (estacionario, con tendencia y/o con estacionalidad).

La *Tabla 6* presenta las especialidades estacionarias de las especialidades en general y el centro modelado de cada especialidad, en la cual se identifican 15 especialidades. Esta tabla ilustra el paso descrito en la presente subsección, y tiene como antecedente el resto de pasos que se describen previamente.

**Tabla 6:** *Especialidades estacionarias de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones*

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje de observaciones sobre el total de observaciones de la especialidad [%]</b>
Cirugía de Cabeza, Cuello y Maxilofacial	Hospital Padre Hurtado	52	71,23%
Cirugía de Tórax	Hospital Dra. Eloísa Díaz	52	33,33%

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje de observaciones sobre el total de observaciones de la especialidad [%]</b>
Cirugía Plástica y Reparadora	Hospital Dr. Sótero del Río	52	32,91%
Coloproctología	Hospital Dr. Sótero del Río	52	32,10%
Endocrinología Pediátrica	Hospital Dr. Sótero del Río	51	32,08%
Genética Clínica	Hospital Dr. Sótero del Río	52	33,33%
Medicina Física y Rehabilitación (Fisiatría Adulto)	Hospital Dra. Eloísa Díaz	52	30,77%
Medicina Interna	Hospital Padre Hurtado	52	25,00%
Neurocirugía	Hospital Dr. Sótero del Río	52	86,67%
Neurología Pediátrica	Hospital Dr. Sótero del Río	52	31,52%
Reumatología	Hospital Dra. Eloísa Díaz	52	28,26%
Urología	Hospital Dr. Sótero del Río	52	25,00%
Cirugía Digestiva	Hospital Dr. Sótero del Río	52	32,70%
Reumatología Pediátrica	Hospital Dr. Sótero del Río	48	52,75%
Traumatología y Ortopedia Pediátrica	Hospital Dr. Sótero del Río	52	31,71%
<b>Número de especialidades</b>	<b>15</b>		

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

En cuanto para las especialidades con tendencia de las especialidades en general, se presenta la *Tabla 7* en la que se observan las especialidades de este tipo y el centro

modelado de cada especialidad. Particularmente se identifican 17 especialidades en esta categoría.

**Tabla 7:** *Especialidades con tendencia de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones*

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Anestesiología	Hospital Padre Hurtado	52	37,68%
Cardiología	Hospital Dr. Sótero del Río	52	25,00%
Cirugía General	Hospital Dr. Sótero del Río	52	25,00%
Cirugía Pediátrica	Hospital Padre Hurtado	52	33,33%
Endocrinología Adulto	Hospital Dr. Sótero del Río	51	25,37%
Gastroenterología Adulto	Hospital Dr. Sótero del Río	52	25,49%
Gastroenterología Pediátrica	Hospital Dr. Sótero del Río	49	31,61%
Hematología	Hospital Dr. Sótero del Río	52	33,33%
Nefrología Pediátrica	Hospital Padre Hurtado	52	33,77%
Psiquiatría Adulto	Hospital Padre Hurtado	52	25,24%
Cardiología Pediátrica	Hospital Dr. Sótero del Río	49	30,06%
Hemato-Oncología Pediátrica	Hospital Dr. Sótero del Río	52	45,61%
Nutriólogo	Hospital Dra. Eloísa Díaz	52	52,00%
Obstetricia	Hospital Dr. Sótero del Río	28	56,00%
Urología Pediátrica	Hospital Dr. Sótero del Río	49	29,88%

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Patología Oral	Hospital Dr. Sótero del Río	33	100,00%
Periodoncia	Hospital Dr. Sótero del Río	52	34,21%
<b>Número de especialidades</b>	<b>17</b>		

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Respecto a las especialidades estacionales de las especialidades en general, se presenta la *Tabla 8* en la que se observan las especialidades de este tipo y el centro modelado de cada especialidad. Particularmente se identifican solo 3 especialidades en esta categoría.

**Tabla 8:** *Especialidades estacionales de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones*

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Diabetología	Hospital Padre Hurtado	48	88,89%
Geriatría	Hospital Padre Hurtado	50	52,63%
Odontopediatría	Hospital Dr. Sótero del Río	52	34,67%
<b>Número de especialidades</b>	<b>3</b>		

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Respecto a las especialidades con estacionalidad y tendencia de las especialidades en general, se presenta la *Tabla 9* en la que se observan las especialidades de este tipo y el centro modelado de cada especialidad. Particularmente se identifican 21 especialidades en esta categoría.

**Tabla 9:** *Especialidades estacionales con tendencia de las especialidades en general, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones*

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Cirugía Cardiovascular	Hospital Dr. Sótero del Río	42	97,67%
Cirugía Vascul Periférica	Hospital Dr. Sótero del Río	52	32,50%
Dermatología	Hospital Dr. Sótero del Río	52	26,00%
Enfermedades Respiratorias del Adulto (Broncopulmonar)	Hospital Dr. Sótero del Río	52	25,74%
Enfermedades Respiratorias Pediátricas (Broncopulmonar Pediátrico)	Hospital Dr. Sótero del Río	49	32,67%
Ginecología Pediátrica y de la Adolescencia	Hospital Dr. Sótero del Río	51	34,00%
Infectología	Hospital Dr. Sótero del Río	52	33,77%
Nefrología Adulto	Hospital Dr. Sótero del Río	52	26,26%
Neurología Adulto	Hospital Padre Hurtado	52	25,00%
Oftalmología	Hospital Dr. Sótero del Río	52	25,12%
Oncología Médica	Hospital Dr. Sótero del Río	48	75,00%
Otorrinolaringología	Hospital Padre Hurtado	52	25,00%
Pediatría	Hospital Padre Hurtado	52	29,55%
Psiquiatría Pediátrica	Hospital Padre	52	29,21%

y de la Adolescencia		Hurtado	
<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Traumatología y Ortopedia	Hospital Dr. Sótero del Río	52	25,37%
Ginecología	Hospital Dr. Sótero del Río	52	25,00%
Cirugía y Traumatología Buco Maxilofacial	Hospital Dr. Sótero del Río	52	33,33%
Endodoncia	Hospital Dr. Sótero del Río	52	33,33%
Ortodoncia y Ortopedia Dento Máxilo Facial	Hospital Dr. Sótero del Río	52	34,44%
Rehabilitación Oral	Hospital Dr. Sótero del Río	52	33,77%
Trastornos Temporomandibulares y Dolor Orofacial	Hospital Dr. Sótero del Río	52	34,90%
<b>Número de especialidades</b>	<b>21</b>		

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Finalmente en la *Tabla 10* se presentan las especialidades con bajas solicitudes y el centro modelado de cada especialidad. Particularmente en este caso se identifican 7 especialidades y cabe notar que estas especialidades no se subdividen en sus patrones de comportamiento. Lo anterior se decide a raíz que son una cantidad reducida de especialidades, por lo que un análisis por subdivisiones no resulta propicio.

**Tabla 10:** Especialidades con bajas solicitudes, el centro modelado, la cantidad de observaciones en el conjunto de entrenamiento y el porcentaje de observaciones sobre el total de observaciones

<b>Especialidad</b>	<b>Centro modelado</b>	<b>Cantidad de observaciones en el conjunto de entrenamiento</b>	<b>Porcentaje sobre el total de observaciones de la especialidad [%]</b>
Inmunología	Hospital Padre Hurtado	52	86,67%
Medicina Familiar	Hospital Dr. Sótero del Río	35	48,61%
Cirugía Plástica y Reparadora Pediátrica	Hospital Dr. Sótero del Río	48	53,33%
Medicina Física Y Rehabilitación Pediátrica (Fisiatría Pediátrica)	Hospital Dra. Eloísa Díaz	50	43,10%
Nutriólogo Pediátrico	Hospital Padre Hurtado	52	83,87%
Implantología Buco Maxilofacial	Hospital Dr. Sótero del Río	27	50,00%
Rehabilitación Oral	Hospital Dr. Sótero del Río	43	64,18%
<b>Número de especialidades</b>	<b>7</b>		

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Respecto al análisis de la representatividad de la selección de centros de destino se afirma que la elección de los centros de destino permite maximizar la cantidad especialidades modeladas. Lo anterior se puede concluir a raíz de las tablas anteriores (*Tabla 6, Tabla 7, Tabla 8, Tabla 9 y Tabla 10*), en las que se observa que existen especialidades en las cuales el centro de destino modelado representa entre el 70% y 100% del total de observaciones en el conjunto de entrenamiento (considerando los cuatro principales centros de destino del SSMSO definidos en *10.2.2.4. Selección y separación por centro de destino*).

## 10.4. Resultados

La presente subsección se hace cargo del objetivo específico: *Desarrollar y evaluar métodos matemáticos de predicción de la demanda de solicitudes de interconsultas de cada especialidad médica y odontológica No GES*. Este último se presenta en la subsección 4.2 *Objetivos Específicos*.

Los resultados a presentar se ordenan de la misma manera que el modelamiento, es decir, los resultados que se obtienen para las especialidades en general y los que se obtienen para las especialidades con bajas solicitudes. Específicamente los resultados de las especialidades en general se dividen en resultados de las especialidades estacionarias, con tendencia, estacionales y estacionales con tendencia.

Los resultados a presentar corresponden al resumen de las métricas de error MAPE que obtienen los métodos predictivos, en el caso de las especialidades en general. Para el caso de las especialidades con bajas solicitudes, corresponden al resumen de las métricas de error MAE. El MAE se utiliza en el último caso mencionado porque da un indicio más certero de la magnitud del error de los pronósticos, ya que al ser una cantidad baja de solicitudes el MAPE tiende a magnificar los errores.

Adicionalmente para las especialidades en general además se enseña el resultado del intervalo  $\mu \pm 3\sigma$  (media más menos tres desviaciones estándar). En este intervalo radican como mínimo el 88,9% de los MAPE que obtienen las proyecciones de los métodos, lo anterior se concluye basándose en la desigualdad de Chebyshev (también escrito Chebychev) [48]. El intervalo en cuestión se utiliza para poder concluir respecto a qué tipo de patrón de las series de tiempo es más complejo de proyectar (estacionaria, con tendencia, estacional o estacional con tendencia). Luego, el orden y contenido de la presentación de resultados se resume a continuación:

1. Especialidades en general
  - a. Especialidades estacionarias
    - i. Tabla resumen de resultados de métricas de error MAPE
    - ii. Tabla resumen del Intervalo  $[0\%, \mu+3\sigma]$
  - b. Especialidades con tendencia
    - i. Tabla resumen de resultados de métricas de error MAPE
    - ii. Tabla resumen del Intervalo  $[0\%, \mu+3\sigma]$
  - c. Especialidades estacionales

- i. Tabla resumen de resultados de métricas de error MAPE
    - ii. Tabla resumen del Intervalo  $[0\%, \mu+3\sigma]$
  - d. Especialidades estacionales con tendencia
    - i. Tabla resumen de resultados de métricas de error MAPE
    - ii. Tabla resumen del Intervalo  $[0\%, \mu+3\sigma]$
- 2. Especialidades con bajas solicitudes
  - a. Tabla resumen de resultados de métricas de error MAE

Los métodos predictivos que se utilizan se declaran en la subsección 8.1. *Modelos*. Los métodos empleados para las especialidades en general son Alisamiento Exponencial, XGBoost, LightGBM, Ensemble Method (ARIMA, TBATS, MLP y ELM) y Medía Móvil. En cuanto para las especialidades con bajas solicitudes, se emplean adicionalmente modelos de Regresión de Poisson. Es oportuno volver a mencionar que los métodos predictivos que se emplean, entrenan sobre series de tiempo exclusivas de una especialidad y centro de destino en particular.

En cuanto al número de variaciones de modelos y especialidades se afirma que se realizan un total de 322 variaciones. De las cuales 280 variaciones ( $5 [modelos] \times 56 [especialidades]$ ) corresponden a las especialidades en general, mientras que 42 variaciones ( $6 [modelos] \times 7 [especialidades]$ ) corresponden a las especialidades con bajas solicitudes.

#### **10.4.1. Especialidades en general**

##### **10.4.1.1. Especialidades estacionarias**

A modo de ejemplificar la lógica de los resúmenes MAPE/MAE de cada caso que se presentan posteriormente (*Tabla 12, Tabla 14, Tabla 16, Tabla 18 y Tabla 20*), se presenta la *Tabla 11*. Ésta contiene las métricas de error MAPE que obtiene cada modelo en las especialidades estacionarias de las especialidades en general. El resto de resultados sin resumir se pueden encontrar en Anexos (Anexo B al E).

**Tabla 11:** Resultados de la métrica MAPE obtenida por los métodos predictivos en las proyecciones, en las especialidades estacionarias de las especialidades en general

<b>Especialidad</b>	<b>MAPE Alisamiento Exponencial [%]</b>	<b>MAPE XGBoost [%]</b>	<b>MAPE LightGBM [%]</b>	<b>MAPE Ensemble Method [%]</b>	<b>MAPE Media Móvil [%]</b>
Cirugía de Cabeza, Cuello y Maxilofacial	26,94%	14,19%	22,28%	26,19%	32,57%
Cirugía de Tórax	35,56%	16,82%	20,05%	25,35%	29,36%
Cirugía Plástica y Reparadora	106,82%	15,98%	18,14%	27,26%	29,18%
Coloproctología	18,44%	9,27%	12,77%	19,90%	22,45%
Endocrinología Pediátrica	25,66%	18,92%	23,84%	28,20%	31,30%
Genética Clínica	25,44%	18,75%	20,51%	27,80%	30,91%
Medicina Física y Rehabilitación (Fisiatría Adulto)	13,41%	12,72%	17,16%	13,36%	33,91%
Medicina Interna	5,72%	5,14%	7,68%	9,13%	17,64%
Neurocirugía	22,42%	16,27%	17,08%	21,54%	24,03%
Neurología Pediátrica	25,45%	24,48%	21,94%	24,22%	28,11%
Reumatología	14,23%	7,49%	11,46%	13,90%	15,16%
Urología	24,90%	13,91%	18,49%	21,61%	28,20%
Cirugía Digestiva	57,94%	16,10%	22,53%	40,79%	56,96%
Reumatología Pediátrica	38,04%	19,52%	36,43%	36,51%	42,18%
Traumatología y Ortopedia Pediátrica	26,15%	26,12%	27,73%	30,36%	32,10%
<b>Promedio</b>	<b>31,14%</b>	<b>15,71%</b>	<b>19,87%</b>	<b>24,41%</b>	<b>30,27%</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Respecto a las especialidades estacionarias de las especialidades en general, se presenta la *Tabla 12* con el resumen de los resultados que se obtienen en este caso. El resto de

tablas resúmenes que se presentan en cada caso siguen la misma lógica. Específicamente esta tabla muestra por cada método predictivo, el MAPE promedio que obtienen sus proyecciones, la desviación estándar de la métrica de error MAPE que obtienen las mismas y el número de veces que obtiene el mejor y el peor rendimiento.

**Tabla 12:** Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionarias de las especialidades en general

<b>Modelo</b>	<b>MAPE promedio [%]</b>	<b>Desviación estándar del MAPE [%]</b>	<b>Nº veces que obtiene el mejor rendimiento</b>	<b>Nº veces que obtiene el peor rendimiento</b>
Alisamiento Exponencial	31,14%	24,16%	0	3
XGBoost	15,71%	5,71%	14	0
LightGBM	19,87%	6,86%	1	0
Ensemble Method	24,41%	8,41%	0	0
Media Móvil	30,27%	9,92%	0	12
<b>Total</b>			<b>15</b>	<b>15</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los resultados presentados en esta tabla, permiten concluir que el método XGBoost obtiene los mejores resultados en la especialidad estacionaria de las especialidades en general. El modelo obtiene el mejor rendimiento en un 93,33% (14/15) de estas especialidades, con un MAPE promedio de 15,71% y una desviación estándar del MAPE de 5,71%. El segundo modelo con mejores resultados corresponde a LightGBM con un MAPE promedio de 19,87% y una desviación estándar del MAPE de 6,86%, el modelo obtiene el mejor rendimiento en un 6,67% (1/15) de estas especialidades.

Respecto al modelo con peores resultados, se concluye que el modelo de la Media Móvil obtiene los peores resultados para la especialidad estacionaria de las especialidades en general. El modelo obtiene el peor rendimiento en un 80,00% (12/15) de estas especialidades, con un MAPE promedio de 30,27% y una desviación estándar del MAPE de 9,92%. El segundo modelo con peores resultados corresponde al Alisamiento Exponencial con un MAPE promedio de 31,14% y una desviación estándar del MAPE de 24,16%, el modelo obtiene el peor rendimiento en un 20,00% (3/15) de estas especialidades.

Luego, en la *Tabla 13* se presenta el MAPE promedio ( $\mu$ ) del total de proyecciones de esta especialidad, la desviación estándar ( $\sigma$ ) de las métricas de error MAPE de las mismas proyecciones. La tabla también presenta el intervalo que abarca desde el 0% (dado que el menor MAPE posible es 0%), a la media más 3 desviaciones estándar ( $\mu+3\sigma$ ). Este último se utiliza posteriormente para definir el tipo de patrón de comportamiento que es más difícil de predecir entre las especialidades en general.

**Tabla 13:** *Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionarias de las especialidades en general*

<b>Tipo de serie de tiempo</b>	<b>MAPE promedio del total de proyecciones (<math>\mu</math>) [%]</b>	<b>Desviación estándar de las métricas de error MAPE (<math>\sigma</math>) [%]</b>	<b>Intervalo [0%, <math>\mu+3\sigma</math>]</b>
Estacionaria	24,28%	13,90%	[0%, 65,97%]

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

#### 10.4.1.2. Especialidades con tendencia

En cuanto a las especialidades con tendencia de las especialidades en general, se presenta la *Tabla 14* con el resumen de los resultados que se obtienen en este caso. Específicamente la tabla muestra por cada método predictivo, el MAPE promedio que obtienen sus proyecciones, la desviación estándar de la métrica de error MAPE que obtienen las mismas y el número de veces que obtiene el mejor y el peor rendimiento.

**Tabla 14:** *Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades con tendencia de las especialidades en general*

<b>Modelo</b>	<b>MAPE promedio [%]</b>	<b>Desviación estándar MAPE [%]</b>	<b>Nº veces que obtiene el mejor rendimiento</b>	<b>Nº veces que obtiene el peor rendimiento</b>
Alisamiento Exponencial	24,67%	6,90%	0	2
XGBoost	12,57%	2,90%	15	0
LightGBM	18,58%	6,27%	2	0
Ensemble Method	22,67%	5,50%	0	0

<b>Modelo</b>	<b>MAPE promedio [%]</b>	<b>Desviación estándar MAPE [%]</b>	<b>Nº veces que obtiene el mejor rendimiento</b>	<b>Nº veces que obtiene el peor rendimiento</b>
Media Móvil	45,30%	21,60%	0	15
<b>Total</b>			<b>17</b>	<b>17</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los resultados presentados en esta tabla, permiten concluir que el modelo XGBoost obtiene los mejores resultados en las especialidades con tendencia de las especialidades en general. El modelo obtiene el mejor rendimiento en un 88,24% (15/17) de estas especialidades, con un MAPE promedio de 12,57% y una desviación estándar del MAPE de 2,90%. El segundo modelo con mejores resultados corresponde a LightGBM con un MAPE promedio de 18,58% y una desviación estándar del MAPE de 6,27%, el modelo obtiene el mejor rendimiento en un 11,76% (2/17) de estas especialidades.

En cuanto a los modelos con peores resultados, se concluye que el modelo de la Media Móvil obtiene los peores resultados para las especialidades con tendencia de las especialidades en general. El modelo obtiene el peor rendimiento en un 88,24% (15/17) de estas especialidades, con un MAPE promedio de 45,30% y una desviación estándar del MAPE de 21,60%. El segundo modelo con peores resultados corresponde al Alisamiento Exponencial con un MAPE promedio de 24,67% y una desviación estándar del MAPE de 6,90%, el modelo obtiene el peor rendimiento en un 11,76% (2/17) de estas especialidades.

Luego, en la *Tabla 15* se presenta el MAPE promedio ( $\mu$ ) del total de proyecciones de estas especialidades, la desviación estándar ( $\sigma$ ) de las métricas de error MAPE de las mismas proyecciones. La tabla también presenta el intervalo que abarca desde el 0% (dado que el menor MAPE posible es 0%), a la media más 3 desviaciones estándar ( $\mu+3\sigma$ ). Este último se utiliza posteriormente para definir el tipo de patrón de comportamiento que es más difícil de predecir entre las especialidades en general.

**Tabla 15:** Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades con tendencia de las especialidades en general

Tipo de serie de tiempo	MAPE promedio del total de proyecciones ( $\mu$ ) [%]	Desviación estándar de las métricas de error MAPE ( $\sigma$ ) [%]	Intervalo [0%, $\mu+3\sigma$ ]
Con Tendencia	24,76%	15,39%	[0, 70,92%]

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### 10.4.1.3. Especialidades estacionales

Concerniente a las especialidades estacionales de las especialidades en general, se presenta la *Tabla 16* con el resumen de los resultados que se obtienen en este caso. Específicamente la tabla muestra por cada método predictivo, el MAPE promedio que obtienen sus proyecciones, la desviación estándar de la métrica de error MAPE que obtienen las mismas y el número de veces que obtiene el mejor y el peor rendimiento.

**Tabla 16:** Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionales de las especialidades en general

Modelo	MAPE promedio [%]	Desviación estándar MAPE [%]	Nº veces que obtiene el mejor rendimiento	Nº veces que obtiene el peor rendimiento
Alisamiento Exponencial	29,52%	2,53%	0	0
XGBoost	16,21%	2,84%	3	0
LightGBM	25,75%	3,81%	0	0
Ensemble Method	31,24%	1,73%	0	1
Media Móvil	49,37%	14,29%	0	2
<b>Total</b>			<b>3</b>	<b>3</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los resultados presentados en esta tabla, permiten concluir que el método XGBoost obtiene los mejores resultados en las especialidades estacionales de las especialidades en general. El modelo obtiene el mejor rendimiento en el 100% (3/3) de estas

especialidades, con un MAPE promedio de 16,21% y una desviación estándar del MAPE de 2,84%. El segundo modelo con mejores resultados corresponde a LightGBM con un MAPE promedio de 25,75% y una desviación estándar del MAPE de 3,81%.

Referente a los métodos con peores resultados, se concluye que el modelo de la Media Móvil obtiene los peores resultados para las especialidades estacionales de las especialidades en general. El modelo obtiene el peor rendimiento en un 66,67% (2/3) de estas especialidades, con un MAPE promedio de 49,37% y una desviación estándar del MAPE de 14,29%. El segundo método con peores resultados corresponde al Ensemble Method con un MAPE promedio de 31,24% y una desviación estándar del MAPE de 1,73%, el modelo obtiene el peor rendimiento en un 33,33% (1/3) de estas especialidades.

Luego, en la *Tabla 17* se presenta el MAPE promedio ( $\mu$ ) del total de proyecciones de estas especialidades, la desviación estándar ( $\sigma$ ) de las métricas de error MAPE de las mismas proyecciones. La tabla también presenta el intervalo que abarca desde el 0% (dado que el menor MAPE posible es 0%), a la media más 3 desviaciones estándar ( $\mu+3\sigma$ ). Este último se utiliza posteriormente para definir el tipo de patrón de comportamiento que es más difícil de predecir entre las especialidades en general.

**Tabla 17:** Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionales de las especialidades en general

<b>Tipo de serie de tiempo</b>	<b>MAPE promedio del total de proyecciones (<math>\mu</math>) [%]</b>	<b>Desviación estándar de las métricas de error MAPE (<math>\sigma</math>) [%]</b>	<b>Intervalo [0%, <math>\mu+3\sigma</math>]</b>
Estacional	30,42%	12,61%	[0%, 68,25%]

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

#### **10.4.1.4. Especialidades estacionales y con tendencia**

Referente a las especialidades estacionales con tendencia de las especialidades en general, se presenta la *Tabla 18* con el resumen de los resultados que se obtienen en este caso. Específicamente la tabla muestra por cada método predictivo, el MAPE promedio que obtienen sus proyecciones, la desviación estándar de la métrica de error MAPE que obtienen las mismas y el número de veces que obtiene el mejor y el peor rendimiento.

**Tabla 18:** Resumen de las métricas de error MAPE que obtienen los métodos predictivos en las especialidades estacionales con tendencia de las especialidades en general

Modelo	MAPE promedio [%]	Desviación estándar MAPE [%]	Nº veces que obtiene el mejor rendimiento	Nº veces que obtiene el peor rendimiento
Alisamiento Exponencial	26,40%	10,40%	0	2
XGBoost	16,83%	6,05%	20	0
LightGBM	22,78%	8,76%	1	0
Ensemble Method	29,07%	21,38%	0	0
Media Móvil	60,26%	43,81%	0	19
<b>Total</b>			<b>21</b>	<b>21</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los resultados presentados en esta tabla, permiten concluir que el método XGBoost obtiene los mejores resultados en las especialidades estacionales con tendencia de las especialidades en general. El modelo obtiene el mejor rendimiento en un 95,24% (20/21) de estas especialidades, con un MAPE promedio de 16,83% y una desviación estándar del MAPE de 6,05%. El segundo modelo con mejores resultados corresponde a LightGBM con un MAPE promedio de 22,78% y una desviación estándar del MAPE de 8,76%, el modelo obtiene el mejor rendimiento en un 4,76% (1/21) de estas especialidades.

En cuanto a los modelos con peores resultados, se concluye que el modelo de la Media Móvil obtiene los peores resultados para las especialidades estacionales con tendencia de las especialidades en general. El modelo obtiene el peor rendimiento en un 90,48% (19/21) de estas especialidades, con un MAPE promedio de 60,26% y una desviación estándar del MAPE de 43,81%. El segundo modelo con peores resultados corresponde al Alisamiento Exponencial con un MAPE promedio de 26,40% y una desviación estándar del MAPE de 10,40%, el modelo obtiene el peor rendimiento en un 9,52% (2/21) de estas especialidades.

Luego, en la *Tabla 19* se presenta el MAPE promedio ( $\mu$ ) del total de proyecciones de estas especialidades, la desviación estándar ( $\sigma$ ) de las métricas de error MAPE de las mismas proyecciones. La tabla también presenta el intervalo que abarca desde el 0%

(dado que el menor MAPE posible es 0%), a la media más 3 desviaciones estándar ( $\mu+3\sigma$ ). Este último se utiliza posteriormente para definir el tipo de patrón de comportamiento que es más difícil de predecir entre las especialidades en general.

**Tabla 19:** Resumen estadístico de las métricas de error MAPE que se obtienen en el caso de las especialidades estacionales con tendencia de las especialidades en general

<b>Tipo de serie de tiempo</b>	<b>MAPE promedio del total de proyecciones (<math>\mu</math>) [%]</b>	<b>Desviación estándar de las métricas de error MAPE (<math>\sigma</math>) [%]</b>	<b>Intervalo [0%, <math>\mu+3\sigma</math>]</b>
Estacional con Tendencia	31,07%	27,05%	[0, 112,21%]

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

#### 10.4.2. Especialidades con bajas solicitudes

Respecto a las especialidades con bajas solicitudes de las especialidades en general, se presenta la *Tabla 20* con el resumen de los resultados que se obtienen en este caso. Específicamente la tabla muestra por cada método predictivo, el MAE promedio que obtienen sus proyecciones, la desviación estándar de la métrica de error MAE que obtienen las mismas y el número de veces que obtiene el mejor y el peor rendimiento.

**Tabla 20:** Resumen de la métrica de error MAE que obtienen los métodos predictivos en las especialidades con bajas solicitudes

<b>Modelo</b>	<b>MAE promedio</b>	<b>Desviación estándar MAE</b>	<b>Nº veces que obtiene el mejor rendimiento</b>	<b>Nº veces que obtiene el peor rendimiento</b>
Alisamiento Exponencial	2,63	1,08	0	1
XGBoost	1,65	0,61	6	0
LightGBM	2,02	0,45	1	0
Ensemble Method	2,65	0,61	0	0
Media Móvil	5,30	3,71	0	3
Regresión de Poisson	4,93	2,90	0	3

<b>Total</b>	7	7
--------------	---	---

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

Los resultados presentados en esta tabla, permiten concluir que el método XGBoost obtiene los mejores resultados en las especialidades con bajas solicitudes. El modelo obtiene el mejor rendimiento en el 85,71% (6/7) de estas especialidades. El segundo modelo con mejores resultados corresponde a LightGBM el que obtiene el mejor rendimiento en el 14,29% (1/7) de estas especialidades.

Por otro lado, respecto a los modelos con peores resultados, se concluye que la Media Móvil es el modelo con peores resultados en las especialidades con bajas solicitudes. Lo anterior a raíz que obtiene el peor rendimiento en el 42,86% (3/7) de estas especialidades y un MAE superior al que obtiene la Regresión de Poisson. Este último corresponde al segundo modelo con peores resultados.

## 10.5. Despliegue

Los resultados de la etapa de Despliegue corresponden a programas simples (scripts) que se hacen entrega a la organización, los que permiten proyectar la demanda mensual futura de las solicitudes de interconsultas de cada especialidad. También se hace entrega a la organización un script que facilita la optimización de los hiperparámetros de los scripts de proyecciones, lo anterior para asegurar una mayor precisión a lo largo del tiempo de los mismos. En la presente subsección se puede encontrar la presentación de cada script junto el detalle de sus características, también se presenta un Plan de Implementación.

Es oportuno mencionar que esta subsección se hace cargo del objetivo específico: *Desarrollar métodos matemáticos que permitan realizar proyecciones de forma periódica de la demanda de las solicitudes de interconsultas de las especialidades No GES, para cada centro de destino del SSMSO.* Este se presenta en la subsección 4.2 *Objetivos Específicos.*

### **10.5.1. Scripts de proyecciones**

Los scripts de proyecciones permiten específicamente realizar estimaciones para todas las especialidades modeladas y los cuatro principales centros de destino de la organización (Hospital Dr. Sótero del Río, Hospital Padre Hurtado, Hospital Dra. Eloísa Díaz y CRS Hospital Provincia Cordillera). Lo anterior quiere decir que para cada uno de estos centros de destino, se desarrolla un script que permite realizar las proyecciones para las especialidades de ese centro en particular (4 scripts). Adicionalmente otra característica de los scripts es que permiten generar los pronósticos a n-meses futuros, dependiendo de lo que el usuario indique.

En cuanto a detalles del funcionamiento interno de los scripts, se afirma que estos consideran los últimos 5 años y 2 meses extra hacia atrás como el periodo para el conjunto de entrenamiento. El periodo mencionado se calcula desde la última fecha con observaciones de cada centro de destino, de igual forma sucede en el caso del conjunto de prueba. El periodo de observaciones del conjunto de prueba corresponde al mes anterior de la fecha que se menciona, lo anterior se realiza de esta forma dado que el último mes con observaciones no siempre tiene completa la información de ese mes.

Los detalles del funcionamiento interno de los scripts se menciona para entender cómo es que los scripts calculan el MAPE de cada método en el conjunto de prueba, de esta forma es posible discernir para cada especialidad cuales son las proyecciones más fidedignas. Específicamente para cada una de estas se escogen las proyecciones del método que obtiene el menor MAPE en el conjunto de prueba. Así es como las proyecciones de los métodos que se emplean se vuelven prácticas, de lo contrario, para cada especialidad se contaría con diversas proyecciones y no habría forma de decidir cuál considerar.

Por otro lado, el contenido de los scripts consiste en una función creada que realiza la preparación de los datos como se indica en la subsección 10.2.2. *Preprocesamiento* para el centro y especialidad en particular. Posteriormente se realizan el número de proyecciones que indique el usuario. Para el entrenamiento de cada modelo se emplean los conjuntos de hiperparámetros previamente definidos de cada especialidad. La función creada en el script permite también calcular el MAPE de cada método como se menciona en el párrafo previo.

### **10.5.2. Script de optimización de hiperparámetros**

El script de optimización de hiperparámetros facilita encontrar las configuraciones de parámetros de cada modelo, los conjuntos de hiperparámetros encontrados son empleados por los scripts de proyecciones. Es oportuno mencionar que el script de optimización de hiperparámetros, permite realizar estas optimizaciones para cada centro de destino y especialidad en particular. En específico se recomienda que se utilice este script en caso de que los hiperparámetros que se están utilizando queden obsoletos, esto es probable que suceda con el paso del tiempo y el contexto en particular de las especialidades.

La sección 13. *RECOMENDACIONES A FUTURO* contiene una recomendación más detallada sobre el uso del script de optimización de hiperparámetros, particularmente detalla en qué situación se recomienda utilizar este script para permitir el mantenimiento de los scripts de proyecciones en un nivel de precisión superior.

### **10.5.3. Plan de Implementación**

El despliegue en este caso termina con la entrega de los scripts mencionados a la organización, esto según se definió con la misma. La implementación propiamente tal la realizan profesionales de la Unidad de Digital del SSMSO. Los profesionales de esta Unidad poseen los conocimientos y herramientas de Ciencia de Datos necesarios para llevar a cabo esta tarea. Por otro lado, el plan de la implementación desarrollado en conjunto con la organización se resume en los puntos siguientes:

1. Generar conexión de los resultados de los scripts a una base de datos de la organización, para lograr que los resultados desemboquen en esta.
2. Publicar en un dashboard (tablero de gestión) gráficos de series de tiempo de las proyecciones resultantes por especialidad, para que estos resultados queden visibles para el resto de la organización.
3. Cálculo de indicadores clave, específicamente la brecha entre la oferta y la demanda de las solicitudes de interconsultas de cada especialidad.

Respecto a las herramientas tecnológicas a utilizar, se recomienda que estos scripts se ejecuten desde Jupyter Notebook (plataforma computacional basada en la web) o en su defecto Google Colab. Particularmente que se ejecuten en un entorno virtual para evitar eventuales conflictos de las librerías utilizadas. Por último, respecto al profesional que ejecute los scripts y en qué dispositivo, se recomienda que sean ejecutados un profesional de la Unidad de Salud Digital del SSMSO y en un computador de la organización.

## **10.6. Estrategias para la toma de decisiones**

El desarrollo de la presente subsección comienza con el desarrollo del objetivo específico: *Aplicar el método matemático a la organización para la toma de decisiones, en el marco del proceso de programación del SSMSO*. Este último se presenta en la subsección *4.2 Objetivos Específicos* y consiste en estrategias que se apoyan en el uso de los scripts de proyecciones otorgados a la organización. Para finalizar también se presentan las recomendaciones más importantes recopiladas en otro trabajo, las cuales están enfocadas en reducir las listas de espera del SSMSO y los tiempos para recibir atención.

### **10.6.1. Estrategias**

Las estrategias que se desarrollan se construyen basándose en las tres principales alternativas que define el Minsal, para anticiparse a una brecha entre la oferta y la demanda de las solicitudes de interconsultas No GES. Las que se declaran en la subsección *10.1. Entendimiento del Negocio*. Estas corresponden a las siguientes:

- Contratación de médicos u odontólogos especialistas que sean requeridos (full time o part time).
- Compra de servicios a otras instituciones de salud públicas o privadas.
- Realizar atenciones en horarios extendidos en los fines de semana.

Las estrategias recomendadas utilizan la información del mismo consolidado de datos SIGTE que se emplea para generar las proyecciones. Estos datos se emplean para calcular las “entradas” (solicitudes de interconsultas generadas), específicamente para el siguiente cálculo:

- Promedio mensual de solicitudes de interconsultas generadas en el SSMSO.

En primer lugar, se define el porcentaje que representan el extra de interconsultas mensuales realizadas en la alternativa de horarios extendidos los fines de semana, sobre la media mensual de interconsultas realizadas. En segundo lugar, con el porcentaje calculado se definen las estrategias que comprenden las alternativas mencionadas.

El cálculo del porcentaje que se menciona implica ciertos supuestos, estos son que en un mes laboral los médicos especialistas del sector público trabajan 176 horas. Lo anterior corresponde al máximo de horas que puede trabajar un médico en este sector (44 horas semanales) [49]. Este supuesto se emplea para el resto del presente trabajo. Adicionalmente se realiza el supuesto que en los fines de semana se puede trabajar máximo 16 horas, esto en concordancia con el límite diario de 8 horas laborales al día en el sector público.

Respecto al porcentaje en cuestión se concluye que este es independiente de la especialidad u centro de destino de la red. Este corresponde a un valor constante. Los cálculos siguientes utilizan  $\mu = \text{media mensual de interconsultas realizadas}$ , y se emplean para llegar a la conclusión anterior.

$$\begin{aligned}
 & \% \text{ de interconsultas extra debido a la alternativa de horarios extendidos en los} \\
 & \text{ fines de semana sobre la media mensual de interconsultas realizadas} \\
 & = \frac{\text{media mensual de interconsultas realizadas bajo la alternativa}}{\mu} \\
 & = \frac{4 \left[ \frac{\text{semanas}}{\text{mes}} \right] \times \text{media de interconsultas realizadas en un fin de semana bajo la alternativa}}{\mu} \\
 & = \frac{4 \left[ \frac{\text{semanas}}{\text{mes}} \right] \times 16 \left[ \frac{\text{horas laborales}}{\text{fin de semana}} \right] \times \text{media de interconsultas realizadas en una hora}}{\mu}
 \end{aligned}$$

$$\begin{aligned}
&= \frac{4 \left[ \frac{\text{semanas}}{\text{mes}} \right] \times 16 \left[ \frac{\text{horas laborales}}{\text{fin de semana}} \right] \times \frac{1}{176} \left[ \frac{\text{mes}}{\text{horas laborales}} \right] \times \mu}{\mu} \\
&= \frac{4 \times 16}{176} \\
&= 0,3636 \\
&= 36,36\%
\end{aligned}$$

Luego, el cálculo en cuestión implica que de realizar la alternativa de atención extendida en los fines de semana, como máximo se puede cubrir un 36,36% de las interconsultas mensuales que actualmente se realizan. Esta conclusión es válida para cualquier especialidad de cualquier centro de destino. Con este cálculo se definen las estrategias que se presentan a continuación.

### *Estrategias*

- a) Si en los próximos 1-3 meses se pronostica un aumento inferior al 36,36% del promedio de la demanda mensual de solicitudes de interconsultas de especialidad, entonces se debe priorizar la alternativa de *“Realizar atenciones en horarios extendidos en los fines de semana”*.
- b) Si en los próximos 1-3 meses se pronostica un aumento superior al 36,36% del promedio de la demanda mensual de solicitudes de interconsultas de especialidad, entonces se debe priorizar la alternativa de *“Compra de servicios a otras instituciones públicas o privadas”*.
- c) Si en los próximos 4-12 meses se pronostica un aumento superior al 36,36% del promedio de la demanda mensual de solicitudes de interconsultas de especialidad, entonces se debe priorizar la alternativa de *“Contratación de médicos u odontólogos especialistas que sean requeridos (full time o part time)”*.

La razón de priorizar la compra de servicios en el caso de la estrategia b), se debe a que la contratación de profesionales tiene un foco a más largo plazo que la opción de compra de servicios. Por otro lado, solo se generan estrategias que contemplan los pronósticos a máximo a 12 meses, lo que se justifica en el hecho que a medida que se proyecta más adelante en el tiempo la incertidumbre en las proyecciones aumenta. De esta forma es

más probable que los pronósticos presenten un error mayor, volviendo inviable estrategias a más largo plazo.

La aplicación de las estrategias se puede ejemplificar mediante una de las especialidades, en este caso la especialidad Oftalmología del Hospital Dr Sótero del Río. Esta especialidad cuenta con una media de 719 [*interconsultas realizadas/mes*]. Si se pronostica que habrá 970 solicitudes en uno de los siguientes 3 meses (aumento del 34,19% con respecto a la media), entonces se sugiere realizar la Estrategia a) de atención en horarios extendidos en los fines de semana.

La ejemplificación de la Estrategia b) considera el mismo caso base de 719 [*interconsultas realizadas/mes*]. Si ahora se pronostica que habrá 1000 solicitudes en uno de los siguientes 3 meses (aumento del 39,08% con respecto a la media), entonces se sugiere comprar servicios a otras instituciones públicas o privadas. En este caso corresponde comprar los servicios de 1 médico oftalmólogo, dada que la diferencia se puede satisfacer con aproximadamente 2 interconsultas realizadas cada hora

$$\left( \frac{1000-719}{176} \left[ \frac{\left[ \frac{\text{interconsultas realizadas}}{\text{mes}} \right]}{\left[ \frac{\text{horas laborales}}{\text{mes}} \right]} \right] \right) \approx 2 \left[ \frac{\text{interconsultas realizadas}}{\text{horas laborales}} \right].$$

Por último, para ejemplificar la Estrategia c) se considera el mismo caso base de 719 [*interconsultas realizadas/mes*] y que ahora se pronostican las solicitudes de los próximos 12 meses. Si se pronostica que una de las proyecciones entre los 4 a 12 meses futuros alcanza las 1300 solicitudes, entonces se sugiere contratar a 1 médico oftalmólogo el que pueda realizar 3 interconsultas cada hora

$$\left( \frac{1300-719}{176} \left[ \frac{\left[ \frac{\text{interconsultas realizadas}}{\text{mes}} \right]}{\left[ \frac{\text{horas laborales}}{\text{mes}} \right]} \right] \right) \approx 3 \left[ \frac{\text{interconsultas realizadas}}{\text{horas laborales}} \right].$$

El caso de la Estrategia c), así como el caso de la Estrategia b) asume que un médico realiza 4 [*interconsultas/hora*]. Lo anterior se establece de esta forma a raíz de que la literatura afirma que una consulta en promedio dura 15 minutos [50].

El escenario que plantea las estrategias mencionadas, permite que las Listas de Espera no crezcan a raíz de un aumento en la demanda de solicitudes de interconsultas. En otras palabras, mantiene la situación actual sin crecimiento de estas listas. Sin embargo, la situación presente corresponde a un escenario de listas de espera abultadas, las que al ritmo actual se tardarían años para resolver en su totalidad.

### **10.6.2. Recomendaciones complementarias**

Los resultado de un trabajo del año 2020 enfocado en analizar la brecha entre oferta y demanda del sector público, concluyen que las listas de espera podrían perdurar por más de 10 años al ritmo actual [51]. Por lo anterior se recomienda tomar otras recomendaciones complementarias a las estrategias mencionadas, estas recomendaciones se extraen del mismo trabajo que se referencia y no son recomendaciones relacionadas al presente trabajo. Estas recomendaciones más importantes se dividen a nivel general [52] [53] y las específicas para el SSMSO [54], estos puntos se presentan a continuación.

#### *Recomendaciones complementarias a nivel general para reducir Lista de Espera*

1. Un criterio básico es dejar para el especialista médico aquellas tareas en que es insustituible como el diagnóstico y la cirugía.
2. La Atención Primaria de Salud (APS) tiene que ser resolutiva derivando hasta el 7% de sus consultas.
3. Aumentar y profundizar el uso de telemedicina o herramientas digitales en los servicios que así lo permiten, como el informe a distancia de radiología compleja o electrocardiografía.
4. Disminuir derivaciones entre especialistas (derivaciones desde el nivel ambulatorio de especialidades).
5. Realizar estrategias para reducir pérdida de horas de atención por no presentación de pacientes (NSP).

## *Recomendaciones complementarias para el SSMSO*

1. Se debe aumentar actividad quirúrgica, buscando minimizar las limitaciones en la oferta de anestesistas y rendimientos dispares de sus diferentes hospitales.
2. Aumentar incorporación de nuevos pabellones, especialistas y subespecialistas.
3. El principal desafío del Servicio es mejorar su ambulatorio de especialidades junto a mejorar y diversificar la oferta del área médica y quirúrgica.

En síntesis, se sugiere a la organización seguir las estrategias que se desarrollan y de forma complementaria también aplicar las recomendaciones enumeradas. Lo anterior para reducir las listas de espera de las Consultas de Especialidad No GES y el tiempo para recibir atención de las mismas, y por último, para que detener el crecimiento de estas listas de espera.

## **11. CONCLUSIONES**

Las primeras conclusiones se basan en los resultados de la *Tabla 12, Tabla 14, Tabla 16, Tabla 18 y Tabla 20* de la subsección *10.4. Resultados*. En el caso de las especialidades con bajas solicitudes y las especialidades en general (estacionarias, con tendencia y/o con estacionalidad) el modelo con mejores resultados corresponde a XGBoost, el que obtiene el mejor rendimiento en el 92,06% (58/63) de las especialidades modeladas. El segundo modelo con mejores resultados corresponde a LightGBM, el que obtiene el mejor rendimiento en 7,94% (5/63) de las especialidades modeladas.

En cuanto a la métricas de error que obtiene estos modelos en el caso de las especialidades en general, se concluye que el modelo XGBoost obtiene un MAPE promedio de 15,21% y una desviación estándar del MAPE de 5,21%. Mientras que el modelo LightGBM obtiene un MAPE promedio de 20,88% y una desviación estándar del MAPE de 7,44%.

Referente a las métricas de error que obtienen estos modelos en las especialidades con bajas solicitudes, se concluye el modelo XGBoost obtiene un MAE promedio de 1,65

unidades y una desviación estándar del MAE de 0,61 unidades. Mientras que el modelo LightGBM obtiene un MAE promedio de 2,02 unidades y una desviación estándar del MAE de 0,45 unidades.

Concerniente a los modelos con los peores resultados de las especialidades en general y las con bajas solicitudes, se concluye que la Media Móvil fue el modelo con peores resultados. El modelo obtiene el peor rendimiento en 80,95% (51/63) de las especialidades modeladas. El segundo modelo con peores resultados en el total de especialidades corresponde al Alisamiento Exponencial, el que obtuvo el peor rendimiento en 12,70% (8/63) de las especialidades modeladas.

Referente a la métricas de error que obtienen estos modelos en el caso de las especialidades en general, se concluye que el modelo de Media Móvil obtiene un MAPE promedio de 47,10% y una desviación estándar del MAPE de 31,51%. Mientras que el modelo Alisamiento Exponencial obtiene un MAPE promedio de 27,31% y una desviación estándar del MAPE de 14,32%.

En cuanto a la métricas de error que obtiene los modelos con peores resultados en el caso de las especialidades con bajas solicitudes, se concluye que el modelo de Media Móvil obtiene un MAE promedio de 5,30 unidades y una desviación estándar del MAE de 3,71 unidades. Mientras que el modelo de Regresión de Poisson obtiene un MAE promedio de 4,93 unidades y una desviación estándar del MAE de 2,90 unidades. Ambos modelos obtienen el peor rendimiento en 42,86% (3/7) de estas especialidades, no obstante, el MAE promedio de la Media Móvil es superior al de la Regresión de Poisson.

La siguiente conclusión tiene como antecedente los resultados de la *Tabla 13*, *Tabla 15*, *Tabla 17* y la *Tabla 19*, y el hecho que en el intervalo  $[0\%, \mu+3\sigma]$  radican como mínimo el 88,9% de las métricas de error MAPE que obtienen los métodos predictivos. Basándose en lo anterior se concluye que en el caso de las especialidades en general, las especialidades estacionales con tendencia son las más difíciles de estimar con el intervalo  $[0, 112,21\%]$ . En segundo, tercer y cuarto lugar, se encuentran las especialidades con tendencia, las estacionales y las estacionarias, con los intervalos  $[0, 70,92\%]$ ,  $[0, 68,25\%]$  y  $[0\%, 65,97\%]$ , respectivamente.

Referente a los scripts que se presentan en la subsección *10.5 Despliegue*, se concluye que permiten brindar al SSMSO la capacidad de generar proyecciones de la demanda de las solicitudes de interconsultas de especialidades No GES. Específicamente permiten

que la organización realice proyecciones periódicas de cada especialidad y para los principales centros de destino. Las proyecciones se acomodan a las necesidades que enfrenta la organización en un determinado momento, en particular por su capacidad de generar proyecciones a n-meses futuros según indique el usuario.

Respecto a las estrategias de gestión en el marco del Proceso de Programación de la subsección 10.6. *Estrategias para la toma de decisiones*, se concluye que estas permiten que las listas de esperas de Consulta de Especialidad No GES detengan su crecimiento. Lo anterior mediante el uso de las proyecciones. Adicionalmente se presentan recomendaciones complementarias para reducir las listas de espera actuales, así como el tiempo para acceder a la atención.

En cuanto al alcance del trabajo, se concluye que la metodología que se utiliza se puede aplicar para el resto de aristas que son parte del Proceso de Programación y no se consideran en el alcance. Estas últimas representan una parte importante de los servicios que acceden los usuarios. Específicamente se puede aplicar la metodología a las demandas de procedimientos, de cirugías, de exámenes, de atenciones de especialidades de control (tratamientos), de atenciones no médicas y la demanda de consultas de especialidades GES.

Respecto a la capacidad de generalización del trabajo, se concluye que la metodología también es aplicable a cualquier otro Servicio de Salud de la Red Asistencial pública. Asimismo lo anterior es factible para cualquier otra institución de salud. Es decir, la metodología en cuestión habilita una oportunidad a otras instituciones de salud, de realizar proyecciones de la demanda de los servicios que estas ofrecen.

Por último, se concluye que el producto del presente trabajo habilita que el SSMSO pueda anticipar cambios en el patrón de las especialidades No GES que se ofrecen y adecuar la oferta a las necesidades de la población. Esto a su vez facilita que las Listas de Espera de este tipo de atenciones no crezcan más y de esta manera atender de forma oportuna a una mayor cantidad de personas. Aún más importante, lo anterior implica que en casos extremos se podría evitar la muerte de pacientes por falta de atención.

## **12. DISCUSIÓN DE RESULTADOS**

En cuanto a los modelos con mejores resultados, se asevera que es inesperado el hecho que el modelo XGBoost obtenga el mejor rendimiento en el 92,06% de las especialidades modeladas. Dado que otros modelos como LightGBM se consideran superiores al modelo XGBoost en diversos aspectos, como se señala en la subsección 8.1. *Modelos*. Asimismo sucede con el Ensemble Method, que al combinar las proyecciones de diversos modelos logran alcanzar una precisión superior a los modelos individuales [55].

En cuanto a los modelos con peores resultados en el caso de las especialidades con bajas solicitudes, se afirma que es inesperado el hecho que el modelo de Regresión de Poisson corresponda al segundo modelo con peores resultados. Corresponde a un hecho inesperado dado que el modelo destaca por su capacidad de predecir conteos estrictamente positivos. Esta cualidad lo vuelve más propicio para las proyecciones de este tipo de especialidades, las que se caracterizan por la cantidad reducida de solicitudes a proyectar.

El hecho que el caso estacionario sea el más fácil de predecir, concuerda con lo que se afirma en la subsección 10.2. *Entendimiento de los Datos*. Por lo tanto, se considera un hallazgo predecible. Sin embargo, no se contaba con un precedente de la dificultad de estimación del resto de tipos de especialidades en general (con tendencia, estacionales y estacionales con tendencia), mediante los resultados obtenidos se sienta el precedente en cuestión.

## **13. RECOMENDACIONES A FUTURO**

En primer lugar, se sugiere seguir las estrategias y recomendaciones que se presentan en la subsección 10.6. *Estrategias para la toma de decisiones*. En ellas se exponen ideas que son capaces de mejorar la situación actual de las listas de espera de las Consultas de Especialidad No GES. De igual forma se exponen estrategias para la toma de decisiones en el marco del Proceso de Programación, considerando como un input las proyecciones de los métodos predictivos que se desarrollan.

En segundo lugar, se recomienda emplear el script de optimización de hiperparámetros para actualizar las variables de entrenamiento que utilizan los modelos. En específico se recomienda optimizar los hiperparámetros cuando la media de la métrica de error

MAPE aumente en un 30%, con respecto a la media que se obtiene luego del primer uso del script de proyecciones. El primer uso del script de proyecciones en este caso hace referencia a la primera ejecución, posterior a la optimización de los hiperparámetros.

En último lugar, se recomienda aplicar metodología al resto de aristas del Proceso de Programación. En específico para la proyección de la demanda de consultas de control (tratamientos), procedimientos, exámenes, cirugías, atenciones no médicas y especialidades GES. Lo anterior se sugiere a raíz que el presente trabajo muestra resultados prometedores en el caso de las solicitudes de interconsultas, y la metodología en cuestión resulta factible de emplear.

## **14. GLOSARIO**

Centro de destino: Establecimiento de salud al cual se deriva a un paciente para que acceda a la atención de especialidad médica u odontológica que necesite.

Centro de origen: Establecimiento de salud desde el cual se deriva a un paciente para que acceda a la atención de especialidad médica u odontológica que necesite.

Lista de espera: Cantidad de pacientes en espera de una atención de alguna especialidad médica u odontológica.

Solicitud de interconsulta: Permite derivar a un paciente a otro profesional sanitario de especialidad.

## 15. BIBLIOGRAFÍA

1. Ministerio de Salud. Servicios de Salud. [en línea] <<https://www.minsal.cl/servicios-de-salud/>> [consulta: 19 octubre 2022].
2. Servicio de Salud Metropolitano Sur Oriente. Comunas de la RED. [en línea] <<https://redsalud.ssmso.cl/comunas-de-la-red/>> [consulta: 20 mayo 2021].
3. Agencia Uno. 23 de diciembre, 2017. Censo 2017: Estas son las 10 comunas más pobladas de Chile. [en línea] 24Horas.cl TVN <<https://www.24horas.cl/nacional/censo-2017-estas-son-las-10-comunas-mas-pobladas-de-chile-2596301>> [consulta: 8 septiembre 2022].
4. Ministerio de Salud. Octubre, 2022. GLOSA 06 Lista de Espera No GES y Garantías de Oportunidad GES Retrasadas LEY DE PRESUPUESTO N° 21.395. 19p. [en línea] <<https://www.minsal.cl/wp-content/uploads/2021/05/Glosa-06-III-Trimestre-2022.pdf>> [consulta: 13 diciembre 2022].
5. Libertad y Desarrollo. MINSAL BAJA ANTIGÜEDAD DE LISTAS DE ESPERA, PERO SUMA 953 MIL PACIENTES NUEVOS EN 2015. 22 de marzo, 2016. [en línea] <<https://lyd.org/centro-de-prensa/noticias/2016/03/32632/>> [consulta: 13 diciembre 2022].
6. Ministerio de Salud. Junio, 2022. GLOSA 06 Lista de Espera No GES y Garantías de Oportunidad GES Retrasadas LEY DE PRESUPUESTO N° 21.395. 47p. [en línea] <<https://www.minsal.cl/wp-content/uploads/2021/05/Glosa-06-II-Trimestre-2022.pdf>> [consulta: 13 diciembre 2022].
7. Ministerio de Salud. Octubre, 2022. GLOSA 06 Lista de Espera No GES y Garantías de Oportunidad GES Retrasadas LEY DE PRESUPUESTO N° 21.395. 21p. [en línea] <<https://www.minsal.cl/wp-content/uploads/2021/05/Glosa-06-III-Trimestre-2022.pdf>> [consulta: 13 diciembre 2022].

8. SSMSO. Unidad de Salud Digital. Lista de espera SSMSO. [en línea] <<https://saluddigital.ssmso.cl/reportes/lista-de-espera-ssmso/>> [consulta: 13 diciembre 2022].
9. R. Chase, F. Jacobs y N. Aquilano. 2009. Administración de Operaciones. 12<sup>a</sup> ed. Bogota, McGraw-Hill. 468p.
10. Martinez, D.A., Zhang, H., Bastias, M. 2019. Prolonged wait time is associated with increased mortality for Chilean waiting list patients with non-prioritized conditions. BMC Public Health 19, 233. [en línea] <<https://doi.org/10.1186/s12889-019-6526-6>> [consulta: 2 julio 2022].
11. Cursando. ¿Cuánto gana un Médico en Chile? Sueldos oficiales actualizados. [en línea] <<https://cursando.cl/medicina/cuanto-gana-medico-chile-sueldos/>> [consulta: 20 abril 2022].
12. Makridakis S, Spiliotis E., Assimakopoulos V. 2022. M5 accuracy competition: Results, findings, and conclusions, International Journal of Forecasting. [en línea] <<https://doi.org/10.1016/j.ijforecast.2021.11.013>> (<https://www.sciencedirect.com/science/article/pii/S0169207021001874>) [consulta: 21 mayo 2022].
13. HYNDMAN, RJ. 19 de noviembre, 2017. M4 Forecasting Competition. [en línea] Rob J Hyndman <<https://robjhyndman.com/hyndsight/m4comp/>> [consulta: 2 diciembre 2022].
14. Ingeniería UChile. 06 de mayo, 2022. La ingeniería detrás del Premio Franz Edelman 2022. [en línea] <<https://ingenieria.uchile.cl/noticias/186221/la-ingenieria-detras-del-premio-franz-edelman-2022>> [consulta: 21 mayo 2022].
15. INFORMS. Franz Edelman Award for Achievement in Advanced Analytics, Operations Research, and Management Science. [en línea] <<https://www.informs.org/Recognizing-Excellence/INFORMS-Prizes/Franz-Edelman-Award>> [consulta: 5 diciembre 2022].

16. Goic M, Bozanic-Leal MS, Badal M, Basso LJ. 2021. COVID-19: Short-term forecast of ICU beds in times of crisis. PLOS ONE 16(1): e0245272. [en línea] <<https://doi.org/10.1371/journal.pone.0245272>> (<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0245272#sec004>) [consulta: 21 mayo 2022].
17. Cawood P, van Zyl T. 2022. Evaluating State of the Art, Forecasting Ensembles and Meta-learning Strategies for Model Fusion. Preprints 2022, 1, 0. <https://doi.org/> [en línea] <<https://arxiv.org/pdf/2203.03279.pdf>> [consulta: 18 octubre 2022].
18. Colkesen I, Ozturk MY. 2022. A comparative evaluation of state-of-the-art ensemble learning algorithms for land cover classification using WorldView-2, Sentinel-2 and ROSIS imagery. Arab J Geosci 15, 942. [en línea] <<https://doi.org/10.1007/s12517-022-10243-x>> [consulta: 7 diciembre 2022].
19. KENWORTHY, A. The M5 forecasting competition. [en línea] Innovating Automation. <<https://www.innovating-automation.blog/m5-forecasting-competition/>> [consulta: 21 mayo 2022].
20. TYAGI, N. 16 de abril, 2021. A Tutorial on Exponential Smoothing and its Types. [en línea] Analytics Steps <<https://www.analyticssteps.com/blogs/tutorial-exponential-smoothing-and-its-types>> [consulta: 16 octubre 2022].
21. LUELLEN, E. 13 de julio, 2021. The Top Five Machine Learning Methods to Forecast Demand for New Products. [en línea] Towards Data Science <<https://towardsdatascience.com/the-top-five-machine-learning-methods-to-forecast-demand-for-new-products-b881ac7e3f32>> [consulta: 20 abril 2022].
22. Data Science Team. 2019. What is Light GBM?. [en línea] DATA SCIENCE <<https://datascience.eu/machine-learning/1-what-is-light-gbm/>> [consulta: 18 octubre 2022].
23. CFI Team. 3 de noviembre, 2022. Ensemble Method. [en línea] Corporate Finance Institute <<https://corporatefinanceinstitute.com/resources/data->

[science/ensemble-methods/#:~:text=What%20are%20Ensemble%20Methods%3F,accuracy%20of%20the%20results%20significantly](#)> [consulta: 2 diciembre 2022].

24. GLEN, S. Conditional Expectation: Definition & Step by Step Example. [en línea] StatisticsHowTo.com: Elementary Statistics for the rest of us! <<https://www.statisticshowto.com/conditional-expectation/>> [consulta: 3 diciembre 2022].

25. GLEN, S. Trimmed Mean / Truncated Mean: Definition, Examples. [en línea] StatisticsHowTo.com: Elementary Statistics for the rest of us! <<https://www.statisticshowto.com/conditional-expectation/>> [consulta: 14 abril 2022].

26. Javatpoint. Arima Model in Python. [en línea] <<https://www.javatpoint.com/arima-model-in-python>> [consulta: 6 octubre 2022].

27. De Livera AM, Hyndman RJ, Snyder RD. 2011. Forecasting Time Series With Complex Seasonal Patterns Using Exponential Smoothing. Journal of the American Statistical Association, 106:496, 1513-1527. [en línea] <[10.1198/jasa.2011.tm09771](https://doi.org/10.1198/jasa.2011.tm09771)> [consulta: 20 abril 2022].

28. IBM. 17 de agosto, 2021. Basic concepts (neural networks) [en línea] <<https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-basics-neural>> [consulta: 7 de diciembre 2022].

29. IBM. 22 de marzo, 2021. Architecture (Multilayer Perceptron) [en línea] <<https://www.ibm.com/docs/kk/spss-statistics/25.0.0?topic=perceptron-architecture-multilayer>> [consulta: 7 octubre 2022].

30. Huang G, Zhu Q, Siew C. 2006. Extreme learning machine: Theory and applications. Volume 70, Issues 1–3, 2006, Pages 489-501, ISSN 0925-2312. [en línea] <<https://doi.org/10.1016/j.neucom.2005.12.126>> (<https://www.sciencedirect.com/science/article/pii/S0925231206000385>) [consulta: 20/04/2022].

31. KUMAR, A. 04 de abril, 2021. Moving Average Method for Time-series forecasting. [en línea] Vitalflux.com <<https://vitalflux.com/moving-average-method-for-time-series-forecasting/#:~:text=The%20moving%20average%20is%20a,range%20while%20moving%20the%20orange>> [consulta: 2 diciembre 2022].
32. Villavicencio J. Introducción a Series de Tiempo. 4p. [en línea] <[http://www.estadisticas.gobierno.pr/iepr/LinkClick.aspx?fileticket=4\\_BxecUaZmg%3D](http://www.estadisticas.gobierno.pr/iepr/LinkClick.aspx?fileticket=4_BxecUaZmg%3D)> [consulta: 7 diciembre 2022].
33. BOOKDOWN. Chapter 8 Poisson Regression. [en línea] <<https://bookdown.org/jaimeisaacp/bookglm/regresi%C3%B3n-de-poisson.html>> [consulta: 14 octubre 2022].
34. Gestión de Operaciones. Error Porcentual Absoluto Medio (MAPE) en un Pronóstico de Demanda. [en línea] <<https://www.gestiondeoperaciones.net/proyeccion-de-demanda/error-porcentual-absoluto-medio-mape-en-un-pronostico-de-demanda/>> [consulta: 15 octubre 2022].
35. Kim S, Kim H. 2016. A new metric of absolute percentage error for intermittent demand forecasts, International Journal of Forecasting. Volume 32, Issue 3, Pages 669-679, ISSN 0169-2070. [en línea] <<https://doi.org/10.1016/j.ijforecast.2015.12.003>> (<https://www.sciencedirect.com/science/article/pii/S0169207016000121>) [consulta: 15 octubre 2022].
36. Sammut C, Webb GI. 2011. Mean Absolute Error. [en línea] Encyclopedia of Machine Learning. Springer, Boston, MA. <[https://doi.org/10.1007/978-0-387-30164-8\\_525](https://doi.org/10.1007/978-0-387-30164-8_525)> [consulta: 14 octubre 2022].
37. IBM. 17 de agosto, 2021. Conceptos básicos de ayuda de CRISP-DM. [en línea] <<https://www.ibm.com/docs/es/spss-modeler/saas?topic=dm-crisp-help-overview>> [consulta: 4 diciembre 2022].

38. Salud Responde. Minsal. Establecimientos de Salud. 02 de junio, 2022. [en línea] <<https://saludresponde.minsal.cl/establecimientos-de-salud/>> [consulta: 4 diciembre 2022].
39. Hospital Félix Bulnes. [en línea] <<http://www.felixbulnes.cl/pdf/interconsulta.pdf>> [consulta: 4 diciembre 2022].
40. Servicio de Salud Metropolitano Sur Oriente. Centros Hospitalarios. [en línea] <<https://redsalud.smsso.cl/centros-hospitalarios//>> [consulta: 4 diciembre 2022].
41. Ministerio de Salud. Autoridades de Salud participan en inicio de obras del Hospital Provincia Cordillera. 21 de julio, 2022. [en línea] <<https://www.minsal.cl/autoridades-de-salud-participan-en-inicio-de-obras-del-hospital-provincia-cordillera/>> [consulta: 4 diciembre 2022].
42. Servicio de Salud Metropolitano Sur Oriente. PROCESO DE PROGRAMACIÓN EN RED. 2022. [en línea] <<https://saluddigital.smsso.cl/wp-content/uploads/2022/11/Proceso-Programacio%CC%81n-SSMSO-v2.o.pdf>> [consulta: 4 diciembre 2022].
43. SUBSECRETARÍA DE REDES ASISTENCIALES. ORIENTACIONES PARA LA PLANIFICACIÓN Y PROGRAMACIÓN EN RED 2022. 2022. 77p. [en línea] <[https://www.minsal.cl/wp-content/uploads/2021/09/2021.09.15\\_Orientaciones-para-la-planificaci%C3%B3n-y-programaci%C3%B3n-de-la-red-2022.pdf](https://www.minsal.cl/wp-content/uploads/2021/09/2021.09.15_Orientaciones-para-la-planificaci%C3%B3n-y-programaci%C3%B3n-de-la-red-2022.pdf)> [consulta: 8 septiembre 2022].
44. SUBSECRETARÍA DE REDES ASISTENCIALES. ORIENTACIONES PARA LA PLANIFICACIÓN Y PROGRAMACIÓN EN RED 2022. 2022. 81p. [en línea] <[https://www.minsal.cl/wp-content/uploads/2021/09/2021.09.15\\_Orientaciones-para-la-planificaci%C3%B3n-y-programaci%C3%B3n-de-la-red-2022.pdf](https://www.minsal.cl/wp-content/uploads/2021/09/2021.09.15_Orientaciones-para-la-planificaci%C3%B3n-y-programaci%C3%B3n-de-la-red-2022.pdf)> [consulta: 8 septiembre 2022].
45. IBM. What is ETL (Extract, Transform, Load)?. [en línea] <<https://www.ibm.com/topics/etl>> [consulta: 12 de abril de 2023]

46. BOBBITT, Z. 10 de mayo, 2021. What is Considered a Good Standard Deviation?. [en línea] Statology <<https://www.statology.org/what-is-a-good-standard-deviation/>> [consulta: 9 diciembre 2022].

47. ÑAU, R. Stationarity and differencing [en línea] Fuqua School of Business, Duke University <[https://people.duke.edu/~rnau/411diff.htm#:~:text=A%20stationarized%20series%20is%20relatively,have%20been%20in%20the%20past!](https://people.duke.edu/~rnau/411diff.htm#:~:text=A%20stationarized%20series%20is%20relatively,have%20been%20in%20the%20past!>)> [consulta: 6 diciembre 2022].

48. SANJUÁN, FJM. 02 de octubre, 2017. Desigualdad de Chebyshev. [en línea] Economipedia.com. <<https://economipedia.com/definiciones/desigualdad-chebyshev-teorema.html>> [consulta: 6 diciembre 2022].

49. sintesis.med.uchile.cl. Aspectos legales relacionados con el ejercicio profesional. [en línea] <<https://sintesis.med.uchile.cl/index.php/profesionales/aspectos-comunes-al-personal-de-salud/aspectos-legales-relacionados-con-el-ejercicio-profesional/995-8-01-2-002#:~:text=Es%20importante%20destacar%20que%20ning%C3%BAAn,diarias%20de%20lunes%20a%20viernes.>>> [consulta: 13 diciembre 2022].

50. Outomuro D, Actis AM. 2013. Estimación del tiempo de consulta ambulatoria en clínica médica. Revista médica de Chile, 141(3), 361-366. [en línea] <<https://dx.doi.org/10.4067/S0034-98872013000300012>> [consulta: 16 diciembre 2022].

51. Danke K, Delteil P, Figueroa R, Infante A, Orellana R, Palavicino P, Silva A, Sandoval H. Diciembre, 2020. ESTUDIO DE BRECHAS DE MÉDICOS Y ODONTÓLOGOS GENERALES Y ESPECIALISTAS EN EL SECTOR PÚBLICO DE SALUD PERÍODO 2020-2030. 248. [en línea] Ministerio de Salud <<https://www.minsal.cl/wp-content/uploads/2021/10/INFORME-ESTUDIO-BRECHAS-MEDICOS-Y-ODONTOLOGOS.pdf>> [consulta: 14 diciembre 2022].

52. Danke K, Delteil P, Figueroa R, Infante A, Orellana R, Palavicino P, Silva A, Sandoval H. Diciembre, 2020. ESTUDIO DE BRECHAS DE MÉDICOS Y ODONTÓLOGOS GENERALES Y ESPECIALISTAS EN EL SECTOR PÚBLICO DE

SALUD PERÍODO 2020-2030. 112p. [en línea] Ministerio de Salud <<https://www.minsal.cl/wp-content/uploads/2021/10/INFORME-ESTUDIO-BRECHAS-MEDICOS-Y-ODONTOLOGOS.pdf>> [consulta: 13 diciembre 2022].

53. Danke K, Delteil P, Figueroa R, Infante A, Orellana R, Palavicino P, Silva A, Sandoval H. Diciembre, 2020. ESTUDIO DE BRECHAS DE MÉDICOS Y ODONTÓLOGOS GENERALES Y ESPECIALISTAS EN EL SECTOR PÚBLICO DE SALUD PERÍODO 2020-2030. 245p. [en línea] Ministerio de Salud <<https://www.minsal.cl/wp-content/uploads/2021/10/INFORME-ESTUDIO-BRECHAS-MEDICOS-Y-ODONTOLOGOS.pdf>> [consulta: 13 diciembre 2022].

54. Danke K, Delteil P, Figueroa R, Infante A, Orellana R, Palavicino P, Silva A, Sandoval H. Diciembre, 2020. ESTUDIO DE BRECHAS DE MÉDICOS Y ODONTÓLOGOS GENERALES Y ESPECIALISTAS EN EL SECTOR PÚBLICO DE SALUD PERÍODO 2020-2030. 215p.[en línea] Ministerio de Salud <<https://www.minsal.cl/wp-content/uploads/2021/10/INFORME-ESTUDIO-BRECHAS-MEDICOS-Y-ODONTOLOGOS.pdf>> [consulta: 13 diciembre 2022].

55. MAKHIJANI, C. 05 octubre, 2020. Advanced Ensemble Learning Techniques. [en línea] Towards Data Science <<https://towardsdatascience.com/advanced-ensemble-learning-techniques-bf755e38cbfb#:~:text=of%20ensemble%20methods-.1.,handle%20this%20type%20of%20data.>> [consulta: 14 diciembre 2022].

## 16. ANEXOS

### Anexo A

*Centros de destino a modelar para cada especialidad el consolidado de datos SIGTE*

<b>Especialidad</b>	<b>Centro de destino a modelar</b>
Anestesiología	Hospital Padre Hurtado
Cardiología	Hospital Dr. Sótero del Río
Cirugía General	Hospital Dr. Sótero del Río
Cirugía de Cabeza, Cuello y Maxilofacial	Hospital Padre Hurtado
Cirugía Cardiovascular	Hospital Dr. Sótero del Río
Cirugía de Tórax	Hospital Dra. Eloísa Díaz
Cirugía Plástica y Reparadora	Hospital Dr. Sótero del Río
Cirugía Pediátrica	Hospital Padre Hurtado
Cirugía Vascul ar Periférica	Hospital Dr. Sótero del Río
Coloproctología	Hospital Dr. Sótero del Río
Dermatología	Hospital Dr. Sótero del Río
Diabetología	Hospital Padre Hurtado
Endocrinología Adulto	Hospital Dr. Sótero del Río
Endocrinología Pediátrica	Hospital Dr. Sótero del Río
Enfermedades Respiratorias del Adulto (Broncopulmonar)	Hospital Dr. Sótero del Río
Enfermedades Respiratorias Pediátricas (Broncopulmonar Pediátrico)	Hospital Dr. Sótero del Río
Gastroenterología Adulto	Hospital Dr. Sótero del Río
Gastroenterología Pediátrica	Hospital Dr. Sótero del Río
Genética Clínica	Hospital Dr. Sótero del Río
Geriatría	Hospital Padre Hurtado
Ginecología Pediátrica y de la Adolescencia	Hospital Dr. Sótero del Río
Hematología	Hospital Dr. Sótero del Río
Infectología	Hospital Dr. Sótero del Río

<b>Especialidad</b>	<b>Centro de destino a modelar</b>
Inmunología	Hospital Padre Hurtado
Medicina Familiar	Hospital Dr. Sótero del Río
Medicina Física y Rehabilitación (Fisiatría Adulto)	Hospital Dra. Eloísa Díaz
Medicina Interna	Hospital Padre Hurtado
Nefrología Adulto	Hospital Dr. Sótero del Río
Nefrología Pediátrico	Hospital Padre Hurtado
Neonatología	Hospital Dr. Sótero del Río
Neurocirugía	Hospital Dr. Sótero del Río
Neurología Adulto	Hospital Padre Hurtado
Neurología Pediátrica	Hospital Dr. Sótero del Río
Oftalmología	Hospital Dr. Sótero del Río
Oncología Médica	Hospital Dr. Sótero del Río
Otorrinolaringología	Hospital Padre Hurtado
Pediatría	Hospital Padre Hurtado
Psiquiatría Adulto	Hospital Padre Hurtado
Psiquiatría Pediátrica y de la Adolescencia	Hospital Padre Hurtado
Radioterapia Oncológica	Hospital Dr. Sótero del Río
Reumatología	Hospital Dra. Eloísa Díaz
Traumatología y Ortopedia	Hospital Dr. Sótero del Río
Urología	Hospital Dr. Sótero del Río
Cardiología Pediátrica	Hospital Dr. Sótero del Río
Cirugía Digestiva	Hospital Dr. Sótero del Río
Cirugía Plástica y Reparadora Pediátrica	Hospital Dr. Sótero del Río
Ginecología	Hospital Dr. Sótero del Río
Hemato-Oncología Pediátrica	Hospital Dr. Sótero del Río
Infectología Pediátrica	Hospital Padre Hurtado
Medicina Familiar del Niño	Hospital Dr. Sótero del Río
Medicina Física Y Rehabilitación	Hospital Dra. Eloísa Díaz

Pediátrica (Fisiatría Pediátrica)

<b>Especialidad</b>	<b>Centro de destino a modelar</b>
Nutriólogo	Hospital Dra. Eloísa Díaz
Nutriólogo Pediátrico	Hospital Padre Hurtado
Reumatología Pediátrica	Hospital Dr. Sótero del Río
Obstetricia	Hospital Dr. Sótero del Río
Traumatología y Ortopedia Pediátrica	Hospital Dr. Sótero del Río
Urología Pediátrica	Hospital Dr. Sótero del Río
Cirugía de Mama	Hospital Dra. Eloísa Díaz
Enfermedades de Transmisión Sexual	Hospital Dr. Sótero del Río
Salud Ocupacional	Hospital Dr. Sótero del Río
Cirugía y Traumatología Buco Maxilofacial	Hospital Dr. Sótero del Río
Cirugía Bucal	Hospital Dra. Eloísa Díaz
Endodoncia	Hospital Dr. Sótero del Río
Implantología Buco Maxilofacial	Hospital Dr. Sótero del Río
Odontopediatría	Hospital Dr. Sótero del Río
Ortodoncia y Ortopedia Dento Máxilo Facial	Hospital Dr. Sótero del Río
Patología Oral	Hospital Dr. Sótero del Río
Periodoncia	Hospital Dr. Sótero del Río
Rehabilitación Oral	Hospital Dr. Sótero del Río
Trastornos Temporomandibulares y Dolor Orofacial	Hospital Dr. Sótero del Río
Operatoria Dental	Hospital Dr. Sótero del Río
Rehabilitación Oral	Hospital Dr. Sótero del Río
Odontología Indiferenciado	Hospital Dr. Sótero del Río

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

## Anexo B

*Resultados de la métrica MAPE obtenida por los métodos predictivos en las proyecciones, en las especialidades con tendencia de las especialidades en general*

<b>Especialidad</b>	<b>MAPE Alisamiento Exponencial [%]</b>	<b>MAPE XGBoost [%]</b>	<b>MAPE LightGBM [%]</b>	<b>MAPE Ensemble Method [%]</b>	<b>MAPE Media Móvil [%]</b>
Anestesiología	29,40%	9,53%	22,08%	19,65%	25,18%
Cardiología	25,94%	14,13%	17,45%	26,08%	32,08%
Cirugía General	16,14%	10,84%	15,11%	15,75%	15,61%
Cirugía Pediátrica	35,83%	16,62%	31,49%	28,68%	48,74%
Endocrinología Adulto	15,66%	11,73%	24,67%	16,49%	34,92%
Gastroenterología Adulto	34,42%	16,25%	13,15%	26,38%	45,78%
Gastroenterología Pediátrica	28,11%	10,78%	25,41%	28,38%	30,65%
Hematología	33,47%	11,32%	20,76%	29,72%	49,41%
Nefrología Pediátrico	14,27%	10,78%	13,17%	13,82%	60,27%
Psiquiatría Adulto	19,84%	12,40%	12,98%	19,65%	36,11%
Cardiología Pediátrica	26,65%	15,34%	27,55%	26,26%	47,27%
Hemato-Oncología Pediátrica	23,29%	17,13%	19,96%	21,04%	75,07%
Nutriólogo	28,65%	15,01%	22,19%	26,87%	60,57%
Obstetricia	25,87%	5,82%	10,29%	29,66%	50,94%
Urología Pediátrica	16,07%	12,04%	15,08%	14,80%	21,39%
Patología Oral	27,34%	12,09%	11,62%	23,21%	32,09%
Periodoncia	18,42%	11,84%	12,84%	18,91%	103,96%
<b>Promedio</b>	<b>24,67%</b>	<b>12,57%</b>	<b>18,58%</b>	<b>22,67%</b>	<b>45,30%</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### Anexo C

*Resultados de la métrica MAPE obtenida por los métodos predictivos en las proyecciones, en las especialidades estacionales de las especialidades en general*

<b>Especialidad</b>	<b>MAPE Alisamiento Exponencial [%]</b>	<b>MAPE XGBoost [%]</b>	<b>MAPE LightGBM [%]</b>	<b>MAPE Ensemble Method [%]</b>	<b>MAPE Media Móvil [%]</b>
Diabetología	27,36%	13,13%	22,19%	30,67%	56,60%
Geriatría	32,31%	16,79%	25,28%	33,18%	32,91%
Odontopediatría	28,89%	18,73%	29,78%	29,86%	58,61%
<b>Promedio</b>	<b>29,52%</b>	<b>16,21%</b>	<b>25,75%</b>	<b>31,24%</b>	<b>49,37%</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

## Anexo D

*Resultados de la métrica MAPE obtenida por los métodos predictivos en las proyecciones, en las especialidades estacionales con tendencia de las especialidades en general*

<b>Especialidad</b>	<b>MAPE Alisamiento Exponencial [%]</b>	<b>MAPE XGBoost [%]</b>	<b>MAPE LightGBM [%]</b>	<b>MAPE Ensemble Method [%]</b>	<b>MAPE Media Móvil [%]</b>
Cirugía Cardiovascular	35,33%	19,54%	19,69%	31,95%	29,02%
Cirugía Vascul Periférica	16,69%	14,08%	19,32%	18,02%	26,18%
Dermatología	15,13%	10,63%	17,38%	18,33%	50,42%
Enfermedades Respiratorias del Adulto (Broncopulmonar)	15,71%	11,12%	12,68%	13,57%	15,78%
Enfermedades Respiratorias Pediátricas (Broncopulmonar Pediátrico)	40,68%	21,47%	33,51%	40,89%	90,64%
Ginecología Pediátrica y de la Adolescencia	29,74%	19,08%	25,77%	30,10%	103,72%
Infectología	29,89%	11,13%	27,40%	22,30%	27,33%
Nefrología Adulto	21,77%	9,01%	12,57%	22,55%	87,55%
Neurología Adulto	21,96%	17,72%	22,18%	22,23%	26,56%
Oftalmología	24,64%	13,94%	22,82%	22,48%	47,04%
Oncología Médica	47,91%	32,13%	44,04%	113,41%	165,45%
Otorrinolaringología	10,94%	9,51%	14,02%	13,71%	19,04%
Pediatría	12,23%	11,97%	12,42%	12,96%	13,12%
Psiquiatría Pediátrica y de la Adolescencia	42,31%	22,15%	29,68%	48,52%	69,30%
Traumatología y Ortopedia	15,19%	12,00%	12,12%	16,19%	18,49%
Ginecología	19,05%	16,80%	19,82%	20,62%	22,84%
Cirugía y Traumatología Buco Maxilofacial	28,14%	12,77%	18,62%	20,26%	114,13%
Endodoncia	31,57%	25,59%	25,27%	32,90%	88,29%
Ortodoncia y Ortopedia	30,42%	23,54%	39,60%	29,92%	123,12%

Dento Máxilo Facial

<b>Especialidad</b>	<b>MAPE Alisamiento Exponencial [%]</b>	<b>MAPE XGBoost [%]</b>	<b>MAPE LightGBM [%]</b>	<b>MAPE Ensemble Method [%]</b>	<b>MAPE Media Móvil [%]</b>
Rehabilitación Oral	35,68%	19,53%	27,04%	32,73%	97,94%
Trastornos Temporomandibulares y Dolor Orofacial	29,43%	19,81%	22,38%	26,78%	29,44%
<b>Promedio</b>	<b>26,40%</b>	<b>16,83%</b>	<b>22,78%</b>	<b>29,07%</b>	<b>60,26%</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.

### Anexo E

*Resultados de la métrica MAE obtenida por los métodos predictivos en las proyecciones en las especialidades con bajas solicitudes*

<b>Especialidad</b>	<b>MAE Alisamiento Exponencial</b>	<b>MAE XGBoost</b>	<b>MAE LightGBM</b>	<b>MAE Ensemble Method</b>	<b>MAE Regresión de Poisson</b>	<b>MAE Media Móvil</b>
Inmunología	2,38	1,46	1,54	2,15	2,15	2,31
Medicina Familiar	1,44	0,78	1,89	2,67	3,00	3,22
Cirugía Plástica y Reparadora	4,54	2,38	2,69	3,38	5,77	5,77
Pediátrica						
Medicina Física Y Rehabilitación	1,54	1,31	1,38	1,77	3,15	3,08
Pediátrica (Fisiatría)						
Pediátrica)						
Nutriólogo	2,21	1,29	2,07	2,43	6,29	6,07
Pediátrico						
Implantología						
Buco	3,00	2,00	2,29	2,71	3,57	3,57
Maxilofacial						
Rehabilitación	3,27	2,36	2,27	3,45	10,55	13,09
Oral						
<b>Promedio</b>	<b>2,6</b>	<b>1,7</b>	<b>2,0</b>	<b>2,7</b>	<b>4,9</b>	<b>5,3</b>

Fuente: Elaborado por el autor utilizando el consolidado de datos SIGTE.