



**UNIVERSIDAD DE CONCEPCIÓN**  
**FACULTAD DE INGENIERÍA**  
**DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**

**PROPUESTA DE OPTIMIZACIÓN DEL AGENDAMIENTO DE CITAS MÉDICAS POST-  
ALTA A PARTIR DE EPICRISIS UTILIZANDO PROGRAMACIÓN LINEAL ENTERA  
MIXTA**

Tesis presentada a la Facultad de Ingeniería de la Universidad de Concepción para  
optar al grado académico de Magíster en Ciencias de la Ingeniería con Mención  
Ingeniería Eléctrica

POR: FRANCISCA BELÉN VALDÉS BRITO

Profesor Guía: ROSA LILIANA FIGUEROA ITURRIAGA

Profesores Co-Guía: DANIEL GERONIMO SBARBARO HOFER

RICARDO ANDRÉS CARTES VELÁSQUEZ

agosto 2025

Concepción, Chile

© 2025 Francisca Belén Valdés Brito

Se autoriza con la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.



## Tabla de Contenido

<b>RESUMEN</b>	<b>VII</b>
<b>ABSTRACT</b>	<b>IX</b>
<b>CAPÍTULO 1. INTRODUCCIÓN</b>	<b>11</b>
<b>CAPÍTULO 2. MARCO TEÓRICO</b>	<b>14</b>
2.1. EPICRISIS MÉDICA	16
2.2. CIE-10	16
2.3. LISTAS DE ESPERA Y NORMATIVA CHILENA	17
2.4. AJUSTE LOGARÍTMICO PARA PROCESAMIENTO DE DATOS	18
2.5. SISTEMAS DE INFORMACIÓN Y TECNOLOGÍAS DIGITALES EN EL ÁMBITO DE LA SALUD Y ATENCIÓN MÉDICA	18
2.5.1 <i>Sistemas y Tecnología de la Información</i>	19
2.5.2 <i>Aprendizaje Automático</i>	20
2.5.3 <i>Heurística</i>	23
2.5.4 <i>Lenguajes de programación</i>	23
2.5.5 <i>Google</i>	24
2.6. MODELOS DE PROGRAMACIÓN LINEAL	26
<b>CAPÍTULO 3. REVISIÓN BIBLIOGRÁFICA</b>	<b>28</b>
3.1. INTRODUCCIÓN	28
3.2. PROGRAMACIÓN, OPTIMIZACIÓN Y HEURÍSTICA	28
3.2.1 <i>Introducción al agendamiento y programación de citas en el ámbito médico</i>	31
3.2.2 <i>Agendamiento de citas médicas ambulatorias</i>	32
3.2.3 <i>Modelos de optimización para programaciones y agendamiento en el ámbito médico</i>	33
3.2.4 <i>Tecnologías de aprendizaje automático y optimización para el agendamiento de citas médicas</i>	36
3.2.5 <i>Implementación de Google Workspace en el ámbito médico</i>	38
3.2.6 <i>Sistemas basados en reglas</i>	39
3.2.7 <i>Ajuste logarítmico en procesamiento de datos</i>	40
3.3. DISCUSIÓN	42
<b>CAPÍTULO 4. HIPÓTESIS Y OBJETIVOS</b>	<b>44</b>
4.1. HIPÓTESIS	44
4.2. OBJETIVOS	44
4.2.1 <i>Objetivo general</i>	44
4.2.2 <i>Objetivos específicos</i>	44
4.3. ALCANCES Y LIMITACIONES	46
<b>CAPÍTULO 5. METODOLOGÍA Y DESARROLLO</b>	<b>48</b>
5.1. BASE DE DATOS	50
5.1.1 <i>Generación de datos sintéticos</i>	51
5.2. PRIORIZACIÓN DE EPISODIOS - SBR	55
5.3. ALGORITMO DE OPTIMIZACIÓN - MILP	59
5.3.1 <i>Levantamiento de información</i>	59
5.3.2 <i>Umbral de prioridad de pacientes</i>	64
5.3.3 <i>Formulación</i>	67
5.3.4 <i>Horizonte y estructura temporal de la planificación</i>	71
5.3.5 <i>Ajustes del algoritmo</i>	72
5.4. VALIDACIÓN DEL SISTEMA	74
5.4.1 <i>Escenarios de evaluación</i>	76
5.4.2 <i>Métricas de validación</i>	80
5.5. IMPLEMENTACIÓN COMPUTACIONAL	82
5.6. ARQUITECTURA DEL SISTEMA	83
5.7. CRITERIOS DE EVALUACIÓN DE LA HIPÓTESIS	84

<b>CAPÍTULO 6. RESULTADOS .....</b>	<b>85</b>
6.1. PRIORIZACIÓN DE EPISODIOS.....	85
6.2. DATOS SINTÉTICOS .....	88
6.3. ALGORITMO DE OPTIMIZACIÓN - MILP.....	89
6.4. COMPLEJIDAD DEL MODELO .....	91
6.5. VALIDACIÓN – MILP.....	92
6.5.1 Grupos de validación .....	99
<b>CAPÍTULO 7. CONCLUSIONES Y TRABAJO FUTURO.....</b>	<b>118</b>
7.1. TRABAJO FUTURO .....	122
<b>CAPÍTULO 8. GLOSARIO .....</b>	<b>125</b>
<b>CAPÍTULO 9. REFERENCIAS .....</b>	<b>127</b>
<b>ANEXO A. APROBACIÓN COMITÉ ÉTICO CIENTÍFICO.....</b>	<b>136</b>
A.1. INFORMACIÓN DESDE EPICRISIS .....	136
A.2. GENERACIÓN CONJUNTO DE DATOS SINTÉTICOS.....	140
<b>ANEXO B. GRÁFICOS PARA ELECCIÓN DEL PERCENTIL PRIORITARIO .....</b>	<b>143</b>
<b>ANEXO C. OCUPACIONES HORARIAS DE BLOQUE Y DÍA POR ESCENARIOS .....</b>	<b>148</b>



## Índice de Tablas

Tabla 5.1. Variables de la base de datos .....	51
Tabla 5.2. Disponibilidad de bloques horarios.....	52
Tabla 5.3. Disponibilidad física de atenciones por bloques horarios y box.....	52
Tabla 5.4. Disponibilidad de médicos y sus horarios. Policlínico 1, Broncopulmonar .....	52
Tabla 5.5. Disponibilidad de médicos y sus horarios. Policlínico 2, Gastroenterología.....	53
Tabla 5.6. Tipo de reglas del SBR a implementar .....	56
Tabla 5.7. Valores y ejemplos de variables para el cálculo del Puntaje de Prioridad.....	58
Tabla 5.8. Preguntas para el Levantamiento del Proceso.....	60
Tabla 5.9. Ejemplo de tabla de un Policlínico del documento Excel.....	61
Tabla 5.10. Tipos de consultas de la interconsulta de Medicina Interna .....	62
Tabla 5.11. Policlínicos y Médicos en el Servicio de Medicina Interna .....	62
Tabla 5.12. Percentiles y porción de pacientes clasificados como Alta Prioridad.....	65
Tabla 5.13. Conjuntos del modelo MILP .....	67
Tabla 5.14. Parámetros del modelo MILP .....	67
Tabla 5.15. Variables de decisión del modelo MILP .....	68
Tabla 5.16. Ajustes aplicados a la matriz de pesos del modelo MILP.....	72
Tabla 5.17. Escenarios de evaluación del algoritmo de optimización .....	79
Tabla 5.18. Grupos de evaluación para evaluación del algoritmo de optimización.....	79
Tabla 5.19. Métricas de validación modelo MILP.....	80
Tabla 5.20. KPIs complementarios de validación modelo MILP .....	81
Tabla 6.1. Métricas clave de validación MILP .....	92
Tabla 6.2. KPI complementarios – MILP .....	93
Tabla 6.3. Tiempos de ejecución de los escenarios - MILP.....	94
Tabla 6.4. Grupo 1: métricas clave .....	100
Tabla 6.5. Grupo 1: KPI complementarios .....	100
Tabla 6.6. Grupo 2: métricas clave .....	103
Tabla 6.7. Grupo 2: KPI complementarios .....	103
Tabla 6.8. Grupo 3: métricas clave .....	107
Tabla 6.9. Grupo 3: KPI complementarios .....	107
Tabla 6.10. Grupo 4: métricas clave .....	111
Tabla 6.11. Grupo 4: KPI complementarios .....	111

**Índice de Ilustraciones**

Ilustración 5.1. Esquema general de la metodología.....	48
Ilustración 5.2. Distribución de puntajes y CDF - E3.....	64
Ilustración 6.1. Base de datos y algunas de sus variables.....	86
Ilustración 6.2. Valores de puntajes de variables y Puntaje Prioridad.....	87
Ilustración 6.3. Comparación visual ocupación horaria por bloque y día - E1 vs E2.....	97




## Resumen

---

En Chile, la epicrisis resume los diagnósticos, procedimientos, complicaciones e indicaciones de egreso de cada paciente y especifica los controles post-alta que debe cumplir. Actualmente, debido a la falta de sistemas automatizados de priorización, en algunos centros de salud el personal clínico debe trasladar físicamente dichas epicrisis hasta los mesones de interconsulta para gestionar las citas médicas. Este proceso manual no discrimina la gravedad de los casos, generando demoras y distribuyendo de forma desigual la carga asistencial.

Esta tesis de magister desarrolló y validó una herramienta de optimización que asigna las citas post-alta de forma automática, equitativa y oportuna, garantizando la atención prioritaria de los pacientes más críticos y respetando las restricciones operativas de los policlínicos.



La propuesta integra un Sistema Basado en Reglas (SBR) utilizando las variables clínicas desde la epicrisis junto a un modelo de Programación Lineal Entera Mixta (MILP), para asignar un puntaje de prioridad calculado a partir de diferentes variables como urgencia de diagnóstico, etapa GES (Garantías Explícitas en Salud), edad, entre otras para agendarlo óptimamente a la agenda. El modelo, se definió sobre un horizonte de 20 días hábiles consecutivos segmentados en bloques horarios de 30 min, considerando un total de 276 bloques y una capacidad de 13 box disponibles.

El modelo fue validado mediante 14 escenarios agrupados variaciones de demanda y capacidad. En condiciones normales, mantuvo la cobertura total (100%) y redujo el retraso

extremo del percentil 95. Ante incrementos progresivos de demanda (hasta +30%), la cobertura permaneció prácticamente completa, y se optimizaron notablemente los retrasos extremos. Escenarios con demanda creciente, se conservó la cobertura total, reduciendo retrasos y liberando horas médicas. Con menos capacidad disponible, también mantuvo cobertura total, disminuyó los tiempos de espera y mejoró la equidad en la distribución de carga laboral.

El método sugiere un proceso automatizado centrado en la prioridad clínica, capaz de absorber fluctuaciones de demanda y capacidad sin comprometer la cobertura ni equidad entre casos. Su implementación disminuiría tiempos de espera, optimizaría recursos y liberaría horas administrativas, convirtiéndose en una referencia y modelo para la implementación de soluciones similares en otros contextos hospitalarios.



## Abstract

---

In Chile, the discharge summary (epicrisis) consolidates each patient's diagnoses, procedures, complications, and discharge instructions, and specifies the required post-discharge follow-ups. Currently, due to the absence of automated prioritization systems, in some health centers clinical staff must physically carry these discharge summaries to referral desks to arrange medical appointments. This manual process does not account for case severity, causing delays and an unequal distribution of clinical workload.

This master's thesis developed and validated an optimization tool that assigns post-discharge appointments automatically, fairly, and in a timely manner, ensuring priority care for the most critical patients while respecting the operational constraints of outpatient clinics.

The proposal integrates a Rule-Based System (RBS) that uses clinical variables from the discharge summary with a Mixed-Integer Linear Programming (MILP) model to assign a priority score computed from variables such as diagnostic urgency, GES stage (Explicit Health Guarantees), age, and others, and to schedule patients optimally. The model was defined over a horizon of 20 consecutive business days segmented into 30-minute time blocks, totaling 276 blocks, with capacity for 13 consultation rooms.

The model was validated through 14 scenarios spanning variations in demand and capacity. Under normal conditions, it maintained full coverage (100% scheduled) and reduced the extreme delay at the 95th percentile. With progressive demand increases (up to +30%), coverage remained nearly complete and extreme delays improved markedly. In scenarios with growing demand, full coverage was preserved while reducing delays and

freeing physician time. With reduced available capacity, it also maintained full coverage, decreased waiting times, and improved equity in workload distribution.

The method suggests an automated, clinically prioritized process capable of absorbing fluctuations in demand and capacity without compromising coverage or equity across cases. Its implementation would shorten waiting times, optimize resources, and free administrative hours, serving as a reference model for similar solutions in other hospital settings.



## Capítulo 1. INTRODUCCIÓN

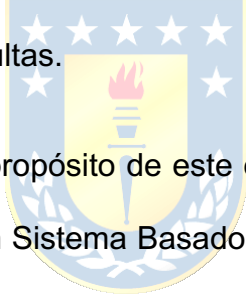
---

En Chile, el procedimiento tras dar de alta a un paciente hospitalizado implica la generación de la epicrisis en formato físico. Es un documento emitido por un establecimiento de salud elaborado por un médico que resume el historial o antecedentes clínicos y medidas terapéuticas correspondientes al paciente [1], como los procedimientos médicos realizados, las complicaciones, los pasos a seguir tras el alta, fecha de los próximos controles, los medicamentos, la dieta y los signos de alerta [2].

El proceso de planificación de los controles post-alta puede experimentar ligeras variaciones según el centro de salud en cuestión, pero en general recae en las enfermeras o los técnicos en enfermería de nivel superior, quienes aseguran la asignación del paciente a la agenda médica [3].

En 2019 el Ministerio de Salud introdujo el Sistema de Gestión de Pacientes con Enfoque de Riesgo para reordenar las listas de espera quirúrgicas y las consultas de especialidad no GES de acuerdo con un factor de riesgo calculado en base a criterios clínicos [4]. Manuel José Irrázaval, asesor del Instituto de Políticas Públicas en Salud hasta principios de 2024, mencionó que no incluye el acumulado de espera por lo que sería perjudicial para los que llevan esperando mucho tiempo [5]. Además, no existe registro actual de que todos los servicios de salud tengan implementado este sistema.

Como resultado, en algunos centros de salud, las consultas post-alta médica no se priorizan de manera automática. En estos casos, el personal administrativo, según la disponibilidad de horarios y agendas de los médicos, registra las consultas de los pacientes o los incluye en las listas de espera correspondientes, sin considerar situaciones individuales para hacer algún tipo de distinción [6]. Esta forma de trabajo se traduce en bajo uso de tecnología de la información (TI), y confirma la ausencia de herramientas que procesen y organicen el flujo de datos clínicos [7]. Además, este tipo de metodologías puede generar cuellos de botella, sobrecargas horarias para algunos profesionales, y la asignación ineficiente de bloques horarios para consultas.



Por todo lo anterior, el propósito de este estudio es desarrollar una solución tecnológica que integre un Sistema Basado en Reglas (SBR) para la priorización clínica con un modelo de Programación Lineal Entera Mixta (MILP). Esta solución busca optimizar la asignación de citas en policlínicos de alta demanda, maximizando la cobertura efectiva de pacientes mediante la priorización de los casos más críticos y una distribución equitativa de la carga de trabajo entre médicos, todo dentro de las restricciones operativas del sistema de salud.

Para ello, en primer lugar, se recopilaron y estructuraron los datos clínicos y operativos necesarios: epicrisis, capacidad de box y horarios médicos. Luego, se diseñó un SBR capaz de calcular un puntaje preliminar de prioridad considerando variables como la urgencia diagnóstica, etapa GES, edad y tiempo desde

el egreso hospitalario. A partir de esta información, se formuló un modelo MILP orientado a maximizar la suma de puntajes atendidos, respetar la capacidad diaria disponible y equilibrar la asignación horaria entre profesionales. Finalmente, el sistema fue validado en 14 escenarios con distintas combinaciones de oferta y demanda, evaluando métricas como la cobertura alcanzada, el uso de recursos y la estabilidad en la priorización clínica.

El estudio integra minería de texto, inteligencia artificial y optimización matemática. El desarrollo siguió cuatro fases: (i) extracción y limpieza de datos reales de epicrisis; (ii) cálculo del puntaje de prioridad; (iii) modelado y resolución MILP sobre un horizonte de 20 días con bloques horarios de 30 min y 13 box; (iv) evaluación del desempeño en escenarios controlados que variaciones de capacidad y demanda. Las implementaciones se realizaron en Python mediante la biblioteca PuLP y contaron con la autorización del Comité Ético Científico del Servicio de Salud Talcahuano (Acta N. °15, 28/03/2024 y Acta N.º 21, 24/04/2025).

Los resultados operativos y el impacto en la gestión hospitalaria se exponen en los capítulos posteriores.

## Capítulo 2. MARCO TEÓRICO

---

La producción mundial de datos está en aumento, y la introducción de sistemas de información en apoyo a los procesos clínicos, administrativos y de gestión colaboran con este aumento constante de información que, generalmente sirve solo para los fines primarios para los que fue creada [8]. Estos sistemas están en instituciones de salud, como hospitales, centros de salud comunitarios y clínicas. La información no estructurada que generan dificulta su análisis inmediato con herramientas convencionales [9], lo que lleva a una subutilización de datos que podrían ser valiosos para la toma de decisiones en procesos clínicos y/o la gestión de recursos [10]. Problema relevante por la demanda constante en los servicios de salud.



La creciente adopción de tecnologías digitales en salud ha marcado un hito significativo en la manera de abordar la atención médica a nivel global. En la Estrategia Mundial sobre Salud Digital 2020-2025 [11] se habla de tecnologías digitales, en la Agenda 2030 para el Desarrollo Sostenible [12\*] se enfatiza la expansión de las tecnologías de la información y las comunicaciones e interconexión en el campo de la salud y, además, en la Estrategia Nacional de Salud para los Objetivos Sanitarios al 2030 [12] la importancia de la información en salud es central. Esta evolución hacia la transformación digital utilizando tecno-

logías puede mejorar la atención centrada en las personas, ampliar los conocimientos basados en la evidencia, además de las habilidades y competencias de los profesionales de la salud.

Según los lineamientos de la Organización Mundial de la Salud (OMS), la información en salud es una de las seis funciones esenciales del sistema de salud, refiriéndose a establecer un sistema de información capaz de generar, analizar y dispersar datos, ayudando a la toma de decisiones y gestión efectiva del sistema de salud. Para 2030 en la Estrategia Nacional para Objetivos Sanitarios, el objetivo es contar con Sistemas de Información (SI) de salud sostenibles, suficientes, integrados y alineados con las exigencias del sector. Esto surge de la insuficiente interoperabilidad entre los distintos actores, estándares insuficientes, datos limitados, infraestructura tecnológica y recursos insuficientes e inadecuados. En resumen, los sistemas de salud deben tener en cuenta la eficiencia y eficacia de sus recursos para brindar un servicio de calidad continuo y oportuno con tal de promover, restablecer o mantener la salud de quien recurre a ellos [13].

Entre estos servicios del sistema está el recurso de la cita médica, fundamental en el tratamiento y seguimiento de patologías, en donde la programación en tiempo razonable y organizada es vital tanto para los recursos limitados de los servicios de salud como para los usuarios de estos. De esta manera, no solo se asegura la sostenibilidad a largo plazo, sino que impulsa el avance hacia una economía circular al abordar las demandas actuales sin descuidar el futuro. Este

enfoque minimiza el desperdicio, fomenta la conservación de recursos y promueve la responsabilidad ambiental y social en todos los ámbitos [14]. De manera similar, la integración de la Inteligencia Artificial (IA) en la práctica clínica puede transformar completamente la eficiencia en la prestación de atención médica al mejorar la atención al paciente y su calidad de vida [15].

### **2.1. Epicrisis Médica**

Este es un documento clave en el agendamiento post-alta. Como menciona el documento de la Superintendencia de Salud, la epicrisis es un documento proveniente de la ficha clínica que recoge información detallada sobre la hospitalización y recomendaciones de seguimiento del paciente una vez se le da el alta médica. Es escrita por profesionales de la salud y juega un rol fundamental en la planificación de consultas posteriores al alta, ya que contiene la información sobre medicamentos, cuidados o controles posteriores. El formato del documento de epicrisis variará según cada centro de salud, pero el contenido va regulado según las normativas del Servicio de Salud de Chile [16]. Al momento de emitir la epicrisis, es revisada y completada por los profesionales encargados del paciente [6].

### **2.2. CIE-10**

La Clasificación Internacional de Enfermedades (CIE) clasifica y agrupa las enfermedades y otros problemas de salud utilizando una codificación específica. Cada código representa una enfermedad o condición específica y se agrupan en categorías más amplias [17]. La CIE se utiliza en diversos contextos del

ámbito de la salud como estadísticas, investigación, gestión en servicios de salud, seguros médicos y educación [18]. Esta se actualiza periódicamente para mantener al día los conocimientos médicos y posibles cambios de las enfermedades. En este contexto, CIE-10 hace referencia a la décima edición.

### **2.3. Listas de espera y normativa chilena**

Con respecto a las listas de espera, la evidencia nacional respalda el uso del percentil 90 (p90), del tiempo de espera, como métrica clave para su monitoreo. El Informe de Conclusiones Diagnóstico – Diseño de Red Asistencial 2023 del Servicio de Salud Biobío utiliza el p90 para detectar brechas de acceso y priorizar intervenciones sobre el 10% más rezagado [19]. Por su parte la Biblioteca del Congreso Nacional (BCN), en su estudio Medición y Reportes de la Lista de Espera No GES (2022), revisa experiencias OCDE y concluye que el p90 es el umbral más comprensible y robusto para la rendición pública, para visibilizar casos extremos y garantizar transparencias [20].

Al menos un 35% de las horas médicas disponibles deben destinarse a primeras consultas de especialidad. Este criterio está formalmente adaptado en los manuales institucionales de hospitales como el Hospital de Coquimbo [21], Hospital de Peñaflor [22], Hospital de La Serena [23], Hospital de Ovalle [24], Hospital Las Higueras [6] y el Instituto Traumatológico Dr. Teodoro Gebauer W. [25]. Esto asegura un equilibrio entre la atención de nuevos pacientes y el seguimiento de aquellos en tratamiento, optimizando la gestión de la lista de espera y garantizando el acceso oportuno a la atención especializada [26].

#### **2.4. Ajuste Logarítmico para Procesamiento de Datos**

Un ajuste logarítmico consiste en la transformación de un conjunto de datos mediante una función logarítmica, lo que permite modelar situaciones donde la relación entre las variables no es lineal. Este tipo de ajuste es particularmente útil cuando los datos presentan una tasa de crecimiento o disminución que varía significativamente con el tiempo, como en el caso de datos con crecimiento exponencial. En tales escenarios, los valores sin transformar pueden mostrar una variabilidad extrema o estar distribuidos de manera sesgada, lo que podría distorsionar los resultados en análisis o modelos predictivos. La transformación logarítmica reduce la influencia de valores atípicos y normaliza las distribuciones, lo que hace que los datos sean más manejables y permitan un análisis más robusto y preciso [27] [28].

#### **2.5. Sistemas de Información y Tecnologías Digitales en el Ámbito de la Salud y Atención Médica**

Es fundamental comprender los SI y tecnologías digitales que pueden intervenir en el proceso de agendamiento de citas médicas. Estos ya fueron mencionados en la Estrategia Nacional de Salud para los Objetivos Sanitarios al 2030 y, conforme a los lineamientos de la Organización Mundial de la Salud (OMS), la información en salud se posiciona como una de las seis funciones esenciales que componen el sistema de salud, refiriéndose a establecer un sistema de ayuda a la toma de decisiones y gestión efectiva del sistema de salud.

### 2.5.1 Sistemas y Tecnología de la Información

Los autores del libro *Management Information Systems* (Gestión de Sistemas de Información) [29], resaltan que los SI tienen una presencia significativa en diversas áreas, como negocios, finanzas, contabilidad, gestión de operaciones, marketing y recursos humanos, entre otras. El libro argumenta que la aplicación de sistemas de información y tecnologías es crucial para el éxito de empresas y organizaciones. Los autores enfatizan que las Tecnologías de la Información (TI) desempeñan roles vitales al mejorar la eficiencia y efectividad de los procesos, siendo esenciales en entornos dinámicos y en conjuntos de componentes interrelacionados con objetivos comunes.

Es así como las TI juegan un papel fundamental en la reingeniería de procesos, debido a la velocidad, capacidades de procesamiento de la información y conectividad de las computadoras y tecnologías de Internet. Al poseer estas características es que pueden aumentar la eficiencia, mejoran las comunicaciones y las colaboraciones entre las personas responsables de la operación y gestión de procesos.

Su arquitectura sigue un diseño conceptual que contiene componentes para operaciones eficientes en las organizaciones. La Plataforma Tecnológica constituye la infraestructura fundamental, englobando cómputo, comunicaciones, internet/intranets, extranet, sistemas informáticos y software integrado de aplicaciones. En paralelo, los Recursos de Datos comprenden diversos tipos de bases

de datos, desde operativas hasta especializadas, como almacenes de datos y bases de datos de Internet/intranet, destinadas a almacenar y proveer información para respaldar procesos comerciales y decisiones [29].

Según lo mencionado, la Tecnología de la Información puede actuar como el cimiento sobre el cual se construye y se impulsan diversos algoritmos, proporcionando herramientas para la manipulación y el análisis de datos a gran escala, como lo son la recopilación, almacenamiento y procesamiento eficiente de grandes conjuntos de datos.

### 2.5.2 Aprendizaje Automático

El Aprendizaje Automático, o *Machine Learning* (ML), este constituye una rama de la IA y ciencias de la computación que se enfoca en el uso de datos y algoritmos para imitar el aprendizaje del ser humano. En esencia, permite que las máquinas aprendan autónomamente a partir de los datos, mejorando progresivamente su rendimiento en el tiempo [30].

Este abarca diferentes categorías que se diferencian en cómo el modelo recibe y procesa la información. Entre las más comunes se encuentran el aprendizaje supervisado, en el que el modelo se entrena con datos etiquetados, es decir, para cada ejemplo se conoce el resultado esperado y el objetivo es predecir el valor de una variable a partir de nuevas entradas. El aprendizaje no supervisado, que utiliza datos no etiquetados y busca identificar patrones, agrupamientos o estructuras de datos. En este último tipo, los datos se representan mediante

modelos estadísticos o probabilísticos, aunque también existen algoritmos que emplean otro tipo de criterios geométricos o de distancia (*K-means*). El aprendizaje semisupervisado, que combina parte del conjunto de datos con etiquetas y otras sin ellas [31]. Por último, el aprendizaje por refuerzo que se basa en que un agente interactúe con un entorno para aprender estrategias que maximicen una recompensa, basándose en prueba y error con retroalimentación [32].

El ámbito de aplicación del ML puede ser diverso ya que puede abarcar desde el reconocimiento de imágenes y el procesamiento del lenguaje natural hasta el diagnóstico médico y la conducción autónoma [33].

En el ámbito de salud podemos nombrar su uso para predecir mortalidad intrahospitalaria, readmisión de pacientes, diagnóstico de enfermedades u otras problemáticas. Los datos administrativos también pueden ayudar a mejorar y optimizar la gestión hospitalaria como predicción de inasistencias de pacientes, organización de horas médicas y pabellón, etc. [34].

#### **A. Sistemas Basados en Conocimiento**

Dentro de estos sistemas se encuentran los sistemas basados en reglas (SBR), utilizados cuando se desean tomar decisiones o procesar información de forma consistente y repetible. Se utilizan cuando se tiene un conjunto de reglas lógicas, reglas determinísticas y conocimientos previos, de esta manera se asimila el pensamiento humano en la resolución de los problemas, por esta razón en un área de estudio relevante [35].

Las reglas que emplean los SBR corresponden típicamente a sentencias if-then (si-entonces), lo que implica que, si se produce un acontecimiento específico, se ejecuta una acción determinada. Según el libro, las reglas pueden clasificarse en [36]:

- **Reglas de producción:** Se utilizan para representar conocimiento en forma de pares condición-acción, donde la acción se desencadena cuando se cumple una condición.
- **Reglas de inferencia lógica:** Estas reglas permiten deducir nuevos hechos a partir de los existentes a través de un proceso formal de razonamiento.
- **Reglas heurísticas:** Estas reglas se basan en la experiencia y proporcionan soluciones prácticas a problemas complejos, aunque no siempre son óptimas.
- **Reglas de control:** Determinan cómo el sistema navega a través de la base de conocimientos y priorizan ciertas acciones en función del contexto actual.

Un sistema basado en reglas se compone principalmente de una base de conocimientos y un motor de inferencia que utiliza diferentes tipos de reglas para guiar su comportamiento, permitiendo que se tomen decisiones de manera estructurada y controlada, asimilando el comportamiento humano en la toma de decisiones [37]. Para Moya, Becerra y Chagoyén en su publicación [38] indican

que lo esencial es el conocimiento específico de alta calidad del que está formada la base de conocimientos del sistema. En donde el conocimiento se adquiere por dos vías principales: el conocimiento factual, documentado en la literatura, y el heurístico, basado en la experiencia y el juicio.

### **2.5.3 Heurística**

La heurística es un enfoque de resolución de problemas que se basa en el uso de reglas prácticas, métodos aproximados o estrategias de búsqueda para encontrar soluciones satisfactorias y razonables donde no siempre se garantiza lo óptimo, pero son útiles para no realizar búsquedas exhaustivas de todas las soluciones posibles [39]. Estos algoritmos pueden ayudar a proporcionar soluciones más rápidas y aceptables cuando se necesite eficiencia en el tiempo de la resolución del problema, como es la optimización enfocada en el área médica [40].

### **2.5.4 Lenguajes de programación**

Existe una amplia variedad de lenguajes de programación, cada uno diseñado con propósitos específicos. Entre los más populares se encuentra Python, un lenguaje de alto nivel (fácil de leer y escribir para el humano) de código abierto orientado a objetos, que no necesita ser compilado y que se compara con Perl, Ruby, Scheme o Java. Python destaca por su sintaxis que facilita la lectura de programas, bibliotecas estandarizadas y un modo interactivo que simplifica la prueba de extractos de código. Además, es versátil, ya que puede integrarse en aplicaciones para proporcionar interfaces programables en diversos sistemas operativos [41].

## 2.5.5 Google

### A. Google Workspace

Google Workspace es un entorno integral de herramientas de productividad y colaboración basado en la nube ofrecido por Google dirigido a empresas, estudiantes, organizaciones sin fines de lucro y particulares, con el propósito de facilitar la organización, colaboración y comunicación en estos [42]. Este conjunto de herramientas incluye correo electrónico, calendario, video llamadas y conferencias, así como almacenamiento en la nube y editores de documentos, hojas de cálculo y presentaciones. Además, ofrece funcionalidades para la comunicación interna, formularios y administración, todo ello con características en tiempo real que brindan flexibilidad y seguridad para los datos de los usuarios. Entre las medidas de seguridad se incluye el cifrado de datos y la protección contra el programas malignos. Google Workspace es escalable para adaptarse a cualquier tamaño de organización o empresa, con opciones de precios ajustables a las necesidades individuales [43].

Esta plataforma alberga sus aplicaciones en donde más de 3 mil millones de usuarios disfrutan de sus herramientas integradas e intercomunicadas, dentro de este conjunto se encuentran [44]:

- Herramientas de almacenamiento y gestión de archivos: Google Drive.
- Herramientas de edición de documentos: Google Docs.
- Herramientas de edición de hojas de cálculo: Google Sheets.
- Herramientas de edición de presentaciones: Google Slides.

- Herramientas de comunicación y colaboración: Gmail, Calendar, Meet, Chat.

Además de esto, este conjunto de aplicaciones ofrece la capacidad de integrar otras aplicaciones personalizadas o permitir que estas personalizadas accedan a archivos dentro de Google Workspace, como aquellas creadas con secuencias de comandos que utilicen la API de Google Drive. Los usuarios pueden emplear estas aplicaciones para una amplia gama de actividades, como la edición de imágenes y videos, la firma y envío de documentos por fax, la gestión de proyectos, la creación de diagramas de flujo, y más. Asimismo, es posible gestionar si los miembros de la organización pueden utilizar la API de Drive para acceder de manera programática al contenido de Drive [45].

### **B. Google Cloud**

Otro de los servicios proporcionados por Google es Google Cloud, que incluye infraestructura, plataformas y software para computación, almacenamiento de datos, análisis de datos y aprendizaje automático. Mientras que Google Workspace proporciona herramientas de productividad y colaboración esenciales para el día a día, Google Cloud ofrece la infraestructura y las capacidades avanzadas de computación necesarias para esas herramientas, donde hay veces en que ambos trabajan de forma colaborativa [46].

## 2.6. Modelos de programación lineal

Los modelos de Programación Lineal (PL) son una técnica de optimización matemática empleada para asignar recursos escasos maximizando o minimizando una función lineal sujeta a un conjunto de restricciones lineales. Esta herramienta se ha extendido a producción, servicios, ambiente, logística, mercadeo, proyectos, finanzas, salud, etc., todas con la finalidad de mejorar la productividad, aprovechar eficientemente los recursos, reducir costos de gestión, satisfacer a los clientes y mejorar la sostenibilidad de los procesos [47].

Una extensión es la Programación Lineal Entera Mixta (MILP), que admite variables de decisión continuas y discretas. La discretización resulta indispensable en problemas de asignación de turnos, box o pacientes, pues las decisiones son binarias (agendar/no agendar) o enteras (número de bloques asignados). Aunque la Programación Entera agrega complejidad combinatoria, los avances en cómputo y los algoritmos de ramificación y acotamiento (su variante ramificación y corte), han acotado los tiempos de resolución [48]; además, se emplean heurísticas para encontrar soluciones iniciales de buena calidad que aceleren la convergencia.

En el contexto del agendamiento médico, la PL y los modelos MILP son herramientas valiosas para optimizar la asignación de recursos como salas quirúrgicas, personal y equipamiento, minimizando costos o tiempos de espera. La posibilidad de combinar variables continuas con variables binarias permite reflejar

con precisión la naturaleza discreta de las decisiones clínicas. De este modo, el MILP ofrece un marco matemático para diseñar agendas que cumplan con restricciones operativas, propicien según criterios clínicos y distribuyan las cargas asistenciales.



## Capítulo 3. REVISIÓN BIBLIOGRÁFICA

---

### 3.1. Introducción

La producción de datos a nivel mundial aumenta día a día, y el ámbito de la salud no es una excepción [1]. La ficha clínica electrónica, también conocida como Registro Electrónico de Salud, es un documento donde se registran los antecedentes relacionados con la salud de las personas. Estos registros, al igual que la epicrisis que deriva de ella, quedan almacenadas en hospitales, centros de salud comunitarios, clínicas u otros [2]. Dada la gran cantidad de documentación por paciente, las técnicas de procesamiento de datos pueden ser utilizadas para extraer información relevante y con el potencial necesario para crear conocimiento y ayudar a los profesionales que trabajan en el área de la salud [3]. Es por esto por lo que la siguiente revisión bibliográfica se orienta a describir el estado de la ciencia en programación de citas médicas, identificar vacíos conceptuales (especialmente post-alta), y justificar la combinación metodológica de un Sistema Basado en Reglas (SBR) para la priorización clínica, con un modelo de Programación Lineal entera Mixta (MILP) para la asignación óptima de bloques de agenda.


### 3.2. Programación, optimización y heurística

La programación, agendamiento y optimización son tópicos ocupados en diferentes industrias en el día a día. Por ejemplo, en un almacén italiano de distribución farmacéutica, los empleados debían dividirse en grupos mutuamente

excluyentes para reducir el riesgo de contagio durante la pandemia de COVID-19. Para resolver el problema, los autores G. Zucchi, M. Iori, y A. Subramanian publican en 2021 una propuesta de un modelo de programación de citas basado en algoritmos de aprendizaje automático [49]. Los datos utilizados para entrenar el modelo fueron reales y las variables del modelo incluyeron asignación de trabajadores en turnos, duración de estos y las restricciones de tiempo de trabajo. Los resultados del estudio muestran que la solución propuesta mejora la del horario manual de la empresa en un 37,3%, además de sugerir que el modelo es escalable a instancias más grandes.

En otro contexto, para 2023 Tseremoglou, Bieber, Santos, Floris y van Kessel abordan en su publicación el problema de programación para el mantenimiento de una flota de aviones [50]. El objetivo fue maximizar la disponibilidad de aeronaves y minimizar costos de mantenimiento cumpliendo requisitos de seguridad utilizando dos modelos de optimización: un modelo de MILP y un modelo de aprendizaje por refuerzo profundo (DRL). Con esto se evaluó el rendimiento de ambos modelos en tres escenarios de mantenimiento para diferentes tamaños de flotas, comparando términos de costo y tiempo de inactividad. Sus resultados indicaron que ambos modelos implementados obtuvieron resultados similares en cuanto a costos y tiempos de inactividad en escenarios de mantenimientos reales.

En un artículo de la revista *Transportation Research Procedia* en 2017, se presentan dos heurísticas basadas en MILP para abordar un problema de programación horaria de trenes [51]. Se creó un horario de 7 días; 300 trenes diarios por 2 días y alrededor de 600 para los demás, con el fin de minimizar la suma de los tiempos de su recorrido. Las pruebas se realizaron en una estación de trabajo Linux con CPLEX 12.2 y para la heurística incremental de ajuste y liberación (IFRH). Los lotes se generaron ordenando los trenes por su hora de salida, y se agregaba un nuevo lote tan pronto como se encontraba una solución factible para el lote anterior. En la optimización independiente, se utilizó una tolerancia relativa de brecha MIP del 100% con un límite de tiempo de ejecución de 2 horas.



Un nuevo modelo de optimización llamado MMCO (*Multi-MILP Model Collaborative Optimization*) fue presentado en 2022 por Liu, Li, Gao y Fan [52] para resolver el problema de planificación y programación de procesos integrados, combinando los beneficios de MILP y heurísticos para lograr equilibrio entre las capacidades de búsqueda global y local, lo que sugiere una capacidad para abordar problemas complejos que requieren una optimización eficiente. El método se prueba en conjunto de datos de Kim, ampliamente utilizado en la literatura, para probar y comparar diferentes métodos de optimización para el problema de planificación y programación de procesos integrados (IPPS). Los resultados se adquieren mediante la implementación en lenguaje C++ y la resolución de los modelos MILP utilizando el solucionador IBM CPLEX. Los autores mencionan que

el método se puede implementar en otros lenguajes de programación y solucionadores de optimización.

Con los modelos de optimización, en particular el MILP, muestran la fortaleza de lograr balances entre utilización y demora sin sacrificar cálculos matemáticos.


### **3.2.1 Introducción al agendamiento y programación de citas en el ámbito médico**

El estudio de la programación operativa se originó en el trabajo del pionero Norman T.J. Bailey, quien en 1952 describió la pauta de intervalos regulares como mecanismo para disminuir la congestión en salas de espera [53]. Desde entonces, la literatura ha evolucionado a modelos matemáticos con mayor sofisticación capaces de incorporar variabilidad en la llegada de los pacientes, duraciones de servicio heterogéneas y políticas de prioridad clínica.

Una visión integral de los desafíos y oportunidades que enfrentan los sistemas de programación en clínicas de atención primaria y especializada fue abordada en un estudio de los autores Diwakar Gupta y Brian Dentonen [54]. En él destacan que, garantizar un acceso rápido y oportuno, es imprescindible contar con reglas de acceso flexibles y con programación anticipada que se adapte a la variabilidad en la urgencia de los pacientes; ello permite equilibrar de forma eficiente la oferta y la demanda de citas. Además, resalta que la capacidad de redirigir flujos de pacientes entre clínicas especializadas y la colaboración ente dis-

tintos proveedores de salud constituyen estrategias clave para gestionar la demanda variable entre áreas particulares. En conjunto, esto resulta fundamental para mejorar eficiencias operativas y satisfacción de pacientes en gestión de citas médicas.

La revisión exhaustiva de Ala y Chen sintetizó más de 150 artículos, entre 2000 y 2021 en la base de datos Web of Science Core Collection, relacionados con los problemas en los servicios de salud y sistematizó 3 niveles de planificación: estratégico por el dimensionamiento de infraestructura, táctico por el diseño de paneles de turnos, y operativo por la asignación diaria de citas [55]. El consenso que surge del análisis es que se deben de proponer métodos para reducir los tiempos de espera de pacientes como resultado de tiempos de inactividad más cortos en los centros de salud.



### **3.2.2 Agendamiento de citas médicas ambulatorias**

En el ámbito de las citas ambulatorias, Fuenzalida del Valle [9] plantea una solución de corto plazo para el Hospital del Salvador en Chile, basada en la categorización de pacientes según gravedad. Su propuesta busca mitigar las extensas listas de espera, fenómeno originado por una demanda sostenida que supera la oferta de especialistas y tratamientos disponibles. El autor modeló un Proceso de Decisión Markoviano y utiliza el proceso de Poisson para representar la frecuencia de llegadas de pacientes [56]. Sobre la base de estos análisis, reco-

mienda aumentar las horas médicas en determinadas especialidades. No obstante, el trabajo no incorpora un optimizador de agenda ni considera alguna métrica legal como el percentil 90 (p90) para tiempos de espera.

Por su parte, en [57] los autores Sharan Srinivas y A. Ravi Ravindran presentan un enfoque alternativo para el agendamiento ambulatorio que programa a los pacientes de forma secuencial, incorporando tanto las ausencias previstas como la heterogeneidad de los distintos grupos de pacientes. El método se estructura en 3 fases: (i) recopilación de datos clínicos y demográficos del paciente, (ii) depuración de la información y (iii) clasificación del riesgo de inasistencias mediante algoritmos de aprendizaje automático alimentados con datos de la ficha electrónica y fuentes externas. A partir de estas predicciones, los autores diseñan y evalúan un conjunto de reglas de programación que ajustan dinámicamente las citas, mejorando la eficiencia y reduciendo los huecos generados por ausencias.

### **3.2.3 Modelos de optimización para programaciones y agendamiento en el ámbito médico**

#### ***A. Modelos de optimización utilizando programación lineal***

En 2023, se plantea un modelo de Programación Entera orientado a optimizar la asignación de personal, pacientes y recursos en centros de salud, con el objetivo de minimizar el costo total sin comprometer la viabilidad ni la eficiencia del programa asistencial [58]. La formulación detalla variables de decisión y restricciones realistas como la disponibilidad de personal, demanda de pacientes,

recursos físicos y presupuestos, y se validó con datos reales de un hospital, mostrando mejoras frente a los métodos tradicionales de programación y evidenciando el potencial de estas técnicas para reducir costos y elevar la eficiencia operativa.

Por su parte, autores en 2019 [59] abordaban la hospitalización de pacientes electivos mediante un enfoque MILP. Con fechas de admisión conocidas y duraciones promedio de estancia por paciente, el modelo busca maximizar la utilización de camas y minimizar los tiempos de espera. Se evaluó en 13 instancias públicas basadas en datos de hospitales de Estados Unidos, Canadá, Australia y Europa, resolviéndose con Gurobi 7.5.2. Los resultados evidenciaron mejorar en la ocupación de recursos y reducción notable en tiempos de espera.

Finalmente, un año más tarde en otra publicación, proponen otro modelo MILP para la programación de citas no urgentes, asignando simultáneamente médico y paciente. El objetivo fue minimizar el tiempo de inactividad y la frecuencia de cambios de médico entre citas consecutivas. El modelo incorpora requisitos terapéuticos, niveles de prioridad y un factor de velocidad asociado a la experiencia de cada médico [60]. Al respetar disponibilidades, límites horarios y duraciones variables de consulta, se logró disminuir las penalizaciones por inactividad y el número de cambios de profesional, mejorando la continuidad de la atención.

### ***B. Modelos basados en heurística***

El artículo en [40] subraya la importancia de la programación en salud y demuestra cómo las estrategias metaheurísticas pueden elevar la eficiencia y la calidad asistencial. A partir de la literatura entre 2010 y 2020, los autores analizan especialmente el Problema de Programación de Admisión de Pacientes (PASP), el cual formulan como un Problema de Programación Lineal Entera cuyo planteamiento puede resolverse con cualquier solucionador de Programación Entera.

Se propone un esquema de 3 etapas para la limpieza hospitalario por personal distribuido [61]. Primero se asignan las tareas a días específicos equilibrando la carga diaria; luego se generan rutas semanales; finalmente, se resuelve un Problema de Programación de Personal (PSP) para minimizar el costo total de mano de obra. El modelo, formulado como MILP, incluye restricciones de una tarea por día, límite de jornada y vinculación de tareas a empleados concretos, y se apoya en heurísticas constructivas y de búsqueda local para alcanzar soluciones eficientes.

Se aborda la programación de servicios médicos de emergencia mediante un modelo MILP que asigna equipos, tiempos de llegada y duraciones de servicio en cada punto de demanda. Implementando C++ con IBM ILOG CPLEX y potenciado por un algoritmo de colonia artificial de abejas, el enfoque se comparó con

algoritmos genéticos y de enjambre de partículas (PSO), demostrando una reducción sustancial del tiempo total de atención y uso óptimo de los recursos limitados en [62].

Por último, un caso de estudio en la revista *International Journal of Supply and Operations Management* [63], presenta un Algoritmo Genético (GA) para la programación de pacientes en urgencias de un hospital de Sfax, Túnez. El modelo entero minimiza el tiempo total de espera bajo restricciones de procedimientos y personal. Las pruebas, realizadas con datos teóricos y reales, logran disminuir los tiempos de espera del paciente entre 18.9% y 27.5%, evidenciando la capacidad del algoritmo para mejorar la utilización de recursos y aliviar el hacinamiento en servicios de urgencia.

#### **3.2.4 Tecnologías de aprendizaje automático y optimización para el agendamiento de citas médicas**

En la sección “Resultados y Análisis” del artículo [55] se comparan distintos enfoques de programación de citas. El primero, Overlapping Scheduling (OLAS), minimiza el tiempo de acceso asignando recursos a pacientes que solicitan atención el mismo día o en pocos días; su lógica consiste en optimizar los intervalos de superposición entre citas y tiempos de servicio, de modo que se reduzcan simultáneamente el costo total de espera del paciente y la inactividad del médico. El segundo, Markovian Scheduling (MSM), aplica teoría de colas: modela la atención mediante cadenas de Márkov que describen las transiciones entre estados clínicos y evalúa la programación considerando la secuencia de los

pasos médicos. El artículo también revisa los marcos de simulación discreta, Discrete Event Simulation (DES) y Agent-Based Simulation (ABS), para problemas ambulatorios, así como los elementos clásicos de la teoría de colas (patrón de llegada, régimen de servicio, reglas de cola y número de recursos). Finalmente, los autores destacan el aporte de la IA a la optimización de procesos sanitarios, citando técnicas como redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN), optimización por colonia de hormigas (ACO), algoritmos genéticos (GA), optimización por enjambre de partículas (PSO) y algoritmo de optimización de ballena (WOA), útiles tanto para agendar citas como para predecir la demanda en urgencias, donde la multiplicidad de horarios y restricciones incide en los retrasos del sistema.

El artículo [57] traslada este debate a las clínicas ambulatorias estadounidenses y se centra en dos problemas recurrentes: la escasez de recursos y la elevada tasa de ausentismo. Los autores proponen un marco de programación de citas basado en aprendizaje automático que utiliza 18 variables independientes para predecir la asistencia del paciente (variable de salida). Su pipeline combina árboles de decisión, regresión logística y validación cruzada. El caso de estudio emplea 76.000 visitas aproximadamente entre 2014 y 2016 en una clínica de medicina en Pensilvania, complementadas con datos demográficos, clínicos y externos (tiempos de traslado de Google Maps y pronósticos meteorológicos). Aunque el *hardware* y *software* no se especifican, la incorporación de fuentes públicas refuerza la calidad de la base de conocimientos y evidencia el potencial

de estos modelos para reducir ausencias y optimizar la asignación de los recursos.

### 3.2.5 Implementación de Google Workspace en el ámbito médico

Aunque Google Workspace no es en sí una plataforma de aprendizaje automático, sus aplicaciones admiten la integración de funcionalidades basadas en ML [45], posibilidad ya mencionada por los autores en [57]. Este potencial se ha aprovechado en el sector de salud para digitalizar las tareas manuales y repetitivas, por ejemplo, e ingreso de datos o la confección de agendas, aliviando la carga administrativa y permitiendo que médicos y personal clínico dediquen más tiempo a la atención directa de los pacientes.

Un ejemplo de este caso es Hunderdon Healthcare (New Jersey), donde herramientas colaborativas en la nube como Google Sheets han automatizado procesos antes manuales; el personal de enfermería ahora registra y hace seguimiento de incidentes con mayor eficiencia, liberando horas que se destinan a cuidados presenciales [64].

Más allá de Workspace, Google Cloud respalda líneas de investigación clínica avanzada. La Cloud Healthcare API facilita la interoperabilidad de los registros electrónicos de salud (EHR) y permite almacenar y procesar grandes volúmenes de datos de forma segura y escalable. Con esta infraestructura, la Stanford School of Medicine integró datos genómicos para impulsar enfoques de me-

dicina personalizada [65]; de igual modo, un estudio sobre detección de retinopatía diabética utilizó Google Cloud para analizar imágenes de retina en tiempo real desde clínicas remotas, emitiendo diagnósticos inmediatos sin necesidad de especialistas in situ [66]. Estas experiencias demuestran cómo la nube de Google refuerza tanto el almacenamiento como el procesamiento eficiente de información clínica.

Por último, organizaciones sanitarias y de ciencias biológicas como CommonSpirit, Cambridge Health Alliance, Roche, Hurley Medical Center, National Institute for Health Research y KPJ Healthcare también emplean Google Workspace para optimizar sus operaciones asistenciales [65].


### 3.2.6 **Sistemas basados en reglas**

El artículo [67] señala que, en los sistemas de citas para pacientes ambulatorios, los enfoques basados en reglas suelen ofrecer soluciones sólidas para la toma de decisiones operativas. Los autores presentan un modelo que introduce distintos criterios de programación, entre ellos la prioridad clínica y el tiempo de espera para gestionar el agendamiento de un entorno real. El sistema opera mediante reglas de producción de tipo “si-entonces”; por ejemplo, prioriza a los pacientes más urgentes o reduce el tiempo de espera cuando se alcanzan ciertos umbrales.

Un segundo uso de esta lógica se ve en donde un sistema basado en reglas facilita la búsqueda de medicamentos. El usuario ingresa su coordenadas y

el fármaco requerido; a partir de allí, el sistema consulta la base de datos y aplica reglas de control para filtrar y priorizar farmacias según disponibilidad y proximidad. El resultado devuelto incluye nombre, dirección, coordenadas y stock, ordenados heurísticamente para mostrar primero las opciones más cercanas y con inventario suficiente [68].

Expandido hacia el soporte clínico, se publicó una guía en donde los autores describen un sistema de apoyo a la decisión clínica (CDSS) que emplea las reglas de producción para recomendar diagnósticos o tratamientos en función de los datos específicos del paciente [69]. Y de manera complementaria, en una revisión de literatura sistemática [70], se ve cómo se utilizan las reglas de inferencia lógica derivadas de árboles de decisión para deducir enfermedades a partir de síntomas y características individuales.



En conjunto, estos trabajos confirman la versatilidad de los sistemas basados en reglas tanto para optimizar agendas ambulatorias como para mejorar la dispensación de medicamentos y el soporte a la decisión clínica, evidenciando su valor como herramienta práctica en distintos dominios de la atención sanitaria.


### **3.2.7 Ajuste logarítmico en procesamiento de datos**

Las transformaciones logarítmicas han probado ser una herramienta eficaz para atenuar la influencia de valores atípicos y corregir la asimetría en conjuntos de datos biológicos. Así lo demuestra [71], donde los autores aplican este tipo de ajuste a concentraciones de biomarcadores en sangre y a variables empleadas

para predecir costos médicos, consiguiendo reducir la distorsión causada por distribuciones desiguales y, en consecuencia, mejorar la precisión de los modelos.

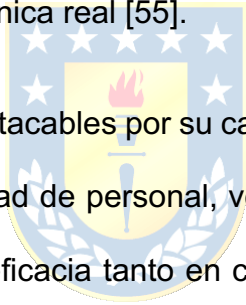
Este mismo principio se extiende al ámbito de la clasificación diagnóstica. En [72] se incorporaron transformaciones logarítmicas dentro de un sistema optimizado de selección de características lo que permitió disminuir la dimensionalidad del conjunto de datos y lograr una identificación más exacta de los desórdenes médicos evaluados. Al suavizarlas variaciones extremas en las variables de entrada, el ajuste logarítmico reforzó la robustez del análisis y elevó el rendimiento del clasificador.

En conjunto, ambos estudios confirman que la escala logarítmica no solo mitiga la influencia de outliers, sino que también mejora la calidad de los procesos de modelado y diagnóstico en contextos clínicos heterogéneos.



### 3.3. Discusión

La revisión de la literatura demuestra que la presión asistencial creciente y la rigidez de los recursos obligan a perfeccionar los procesos operativos en salud [54], [55]. Problemas como el agendamiento de citas, la asignación del personal y la gestión intrahospitalaria inciden directamente en la calidad de atención y en los costos del sistema [55], [58]-[63]. En respuesta, estudios han empleado modelos matemáticos, metaheurística y técnicas de IA para reducir tiempos de espera y optimizar recursos [40], [57]-[60], [61]-[63]. No obstante, gran parte de estos trabajos permanece en el ámbito teórico o se valida en entornos diferentes, lo que limita su aplicabilidad clínica real [55].



Los modelos MILP son destacables por su capacidad de incorporar múltiples restricciones como disponibilidad de personal, ventanas de atención y duración de servicios, y han mostrado eficacia tanto en citas ambulatorias como en programación de hospitalizaciones [58]-[60]. En particular, se observan mejoras en las atenciones y utilización de recursos en citas no urgentes [60] y en la ocupación de camas y reducción de esperas en hospitalización electiva [59]. Sin embargo, pocos consideran las normativas, como el percentil 90 para las listas de espera o GES para estudios en Chile, presentando un obstáculo para el estudio crítico y la adopción en la práctica local [9].

Paralelamente, se registran avances en el aprendizaje automático para predecir inasistencias y apoyar a la priorización clínica. Por ejemplo, marcos que

integran variables clínicas y demográficas para anticipar las ausencias y ajustar dinámicamente la programación [57], y enfoques de categorización de gravedad para orientar decisiones operativas [9]. No obstante, apenas se exploran técnicas capaces de extraer automáticamente información clínica relevante de las epícrisis, pese a la oportunidad que ofrecen los registros electrónicos para generar ese tipo de conocimiento aplicable [1]-[3]. Además, la integración de estos algoritmos con optimizadores MILP sigue siendo escasa, infrautilizando los datos disponibles en los registros electrónicos. Del mismo modo, la etapa post-alta médica, calve para evitar readmisiones y garantizar la continuidad de cuidados, permanece prácticamente ausente en la literatura, pese a su impacto sobre la atención primaria y el cumplimiento de garantías GES [55].

En consecuencia, esta tesis atiende este vacío mediante una solución híbrida que combina la extracción de información clínica, priorización basada en reglas y optimización matemática, alineada con los estándares regulatorios nacionales. La evidencia respalda el uso de sistemas basados en reglas para la toma de decisiones operativas y soporte clínico [67]-[70], y formulaciones MILP para la asignación óptima de recursos y agendas [58]-[60]. Su integración apunta a un sistema de agendamiento más eficiente, equitativo y controlado, donde las citas respondan a la situación clínica y no solo al orden de llegada, reduciendo demoras, aliviando la carga administrativa y mejorando la experiencia de pacientes y profesionales [55], [57], [59], [60].

## Capítulo 4. HIPÓTESIS Y OBJETIVOS

---

### 4.1. Hipótesis

Dado el problema de priorización y agendamiento de controles post-alta en policlínicos, se plantea que un sistema basado en Programación Lineal Entera Mixta, complementado con un Sistema Basado en Reglas, puede mejorar la asignación de citas utilizando datos de epicrisis y recursos hospitalarios, optimizando el agendamiento al incrementar el número de episodios de mayor prioridad agendados.

### 4.2. Objetivos

#### 4.2.1 Objetivo general

Desarrollar una solución tecnológica que automatice y optimice el agendamiento de citas post-alta en policlínicos, mejorando la priorización de episodios según su complejidad clínica y la disponibilidad de los recursos hospitalarios, en centros de salud que actualmente no cuenten con un sistema de agendamiento automatizado.

#### 4.2.2 Objetivos específicos

- Recopilar y estructurar la información y la base de datos, incluyendo datos de epicrisis y disponibilidad de recursos hospitalarios (médicos, boxes, horarios), para alimentar el modelo de optimización.
- Diseñar y desarrollar un Sistema Basado en Reglas (SBR) que permita realizar una priorización preliminar de los pacientes post-alta, considerando factores clínicos.

- Formular un modelo de Programación Lineal Entera Mixta (MILP) que optimice el agendamiento de controles post-alta, asegurando la asignación eficiente de los recursos disponibles, utilizando la información, datos y variables previamente recopiladas.
- Evaluar el desempeño del sistema propuesto mediante métricas cuantitativas, centradas en la cantidad de pacientes con mayor puntaje de prioridad agendados, utilizando el puntaje de prioridad ponderado promedio de las agendas de los policlínicos.



### 4.3. Alcances y limitaciones

A continuación, se presentan los alcances y limitaciones que rigieron el estudio cuyo objetivo fue desarrollar un algoritmo de agendamiento de controles post-alta médica en el Hospital Las Higuera de Talcahuano. La investigación se centró en dos policlínicos seleccionados por concentrar la mayor demanda del servicio; esta elección permitió manejar una cantidad de datos acorde con la complejidad de la optimización y asegurar el correcto funcionamiento del sistema.

Alcances:

- I. **Desarrollo del algoritmo:** Se diseñó y programó un algoritmo que optimiza el agendamiento de citas médicas para controles post-alta, incorporando restricciones clínicas y operativas propias del hospital.
- II. **Enfoque en alta demanda:** La solución se aplicó a los dos policlínicos con mayor carga asistencial, abordando los desafíos más críticos y generando resultados directamente relevantes para el servicio.
- III. **Pruebas y validación:** El algoritmo se evaluó con datos reales anonimizados y escenarios simulados, lo que permitió medir su desempeño y ajustarlo antes de considerar una implementación extensiva.

Limitaciones:

- I. **Escenario simulado:** Aunque se emplearon datos históricos, parte de la validación se realizó en un entorno de simulación; por tanto, los resultados podrían no reproducir por completo la dinámica del hospital en tiempo real.

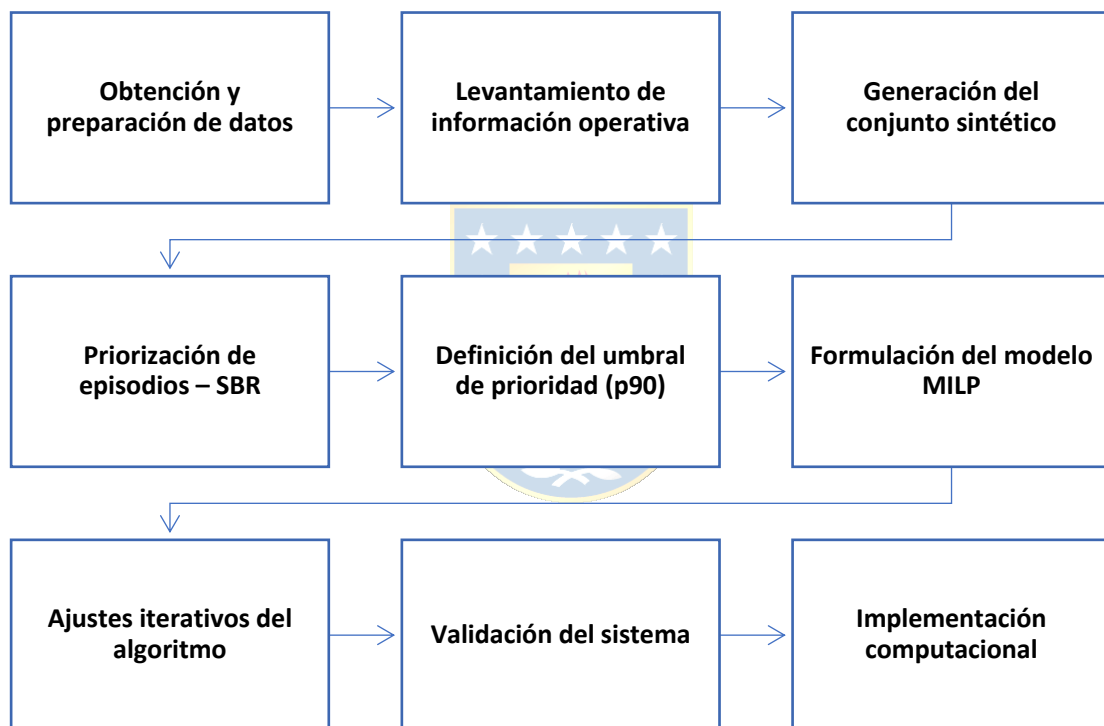
- II. **Datos anonimizados:** Por motivos éticos y de privacidad, se trabajó con datos despersonalizados, lo cual restringió la posibilidad de calibrar el algoritmo frente a particularidades clínicas de pacientes concretos.
- III. **Alcance limitado a dos policlínicos:** El estudio abarcó únicamente dos unidades, lo que limita la extrapolación de los hallazgos a otros servicios o especialidades del hospital.
- IV. **Restricciones de recursos:** La eventual implementación a escala podría enfrentar restricciones adicionales de infraestructura y personal que no fueron completamente abordadas en esta fase.
- V. **Límite de tiempo:** El proyecto se desarrolló bajo un plazo acotado, lo cual condicionó la profundidad de las pruebas y la aptitud del análisis de sensibilidad.



## Capítulo 5. METODOLOGÍA Y DESAROLLO

---

En los apartados siguientes se describen los principales pasos desde la obtención de los datos clínicos hasta la validación del modelo de optimización. Para una mejor comprensión, la Ilustración 5.1 muestra un esquema general de la metodología, ajustado a la secuencia real de trabajo:



**Ilustración 5.1.** Esquema general de la metodología.

**Fuente:** Elaboración propia.

- I. **Obtención y preparación de datos:** base de datos inicial con 266 episodios reales (2020-2022), obtenidos con autorización ética.
- II. **Levantamiento de información operativa:** entrevistas y observación directa para identificar restricciones reales y capacidades operativas.
- III. **Generación del conjunto sintético:** creación de 358 episodios nuevos mediante simulación, considerando capacidades reales de policlínicos.
- IV. **Priorización de episodios – SBR:** se asignan los puntajes en función de las variables clínicas y logísticas.
- V. **Definición del umbral de prioridad (p90):** selección del percentil 90 como corte para casos de alta prioridad, basado en análisis de distribución.
- VI. **Formulación del modelo MILP:** definición de conjuntos, parámetros, variables, función objetivo y restricciones.
- VII. **Ajustes iterativos del algoritmo:** modificación de pesos y restricciones con pruebas del modelo.
- VIII. **Validación del sistema:** ejecución de los escenarios E1-E14, cálculo y análisis de KPIs para comparar desempeño.
- IX. **Implementación computacional:** desarrollo del código en Python, PuLP. Generación y exportación de agendas optimizadas y comparación de resultados.

### 5.1. Base de datos

El proyecto empleó inicialmente una base de datos facilitada por el Servicio de Medicina Interna del Hospital Las Higueras, previa autorización del Comité Ético Científico del Servicio de Salud de Talcahuano, según Acta N. °15 de la sesión ordinaria del 28 de marzo de 2024, véanse A.1 del Anexo A. Esta contenía 266 episodios de hospitalización de pacientes adultos correspondientes a los años 2020, 2021 y 2022.

Durante la fase de validación del modelo se constató que dicha muestra no aportaba la representatividad necesaria para evaluar correctamente el desempeño del algoritmo MILP. Por ello se solicitó y obtuvo el segundo conjunto de datos de 358 nuevos episodios, generada sintéticamente en base a los datos proporcionados y autorizados inicialmente por el Comité Ético Científico. Este segundo conjunto fue de igual manera autorizado mediante Acta N.º 21 de la sesión ordinaria del 24 de abril de 2025, véase A.2 en Anexo A, por el Comité Ético Científico.

Cada registro de la base de datos incluye: edad, diagnóstico de egreso (CIE-10), número de días de hospitalización, fecha de egreso, variable GES e indicaciones de egreso incluyendo policlínico y periodo de tiempo hasta el control post-alta. Estas variables y su tipificación se describen en la Tabla 5.1.

Tabla 5.1. Variables de la base de datos

Variable	Tipo dato	Formato o Rango	Ejemplo
Edad	Numérico	18-120 años	20
Diagnóstico de egreso	Categorico nominal	CIE-10	COVID-19
Número de días de hospitalización	Numérico	0-∞ días	3
Fecha de egreso	Numérico	DD-MM-AAAA	19-02-2020
Variable GES	Categorico ordinal	GES	Caso en Seguimiento
Indicaciones de egreso	Texto	Texto libre	Control poli cardio en 3 días.
Policlinico	Categorico nominal	Texto	Cardiología
Temporalidad	Numérico	1-∞ días	3
Fecha Indicada	Numérico	DD-MM-AAAA (Fecha de Egreso + Temporalidad)	22-02-2020
Días para la Fecha Indicada	Numérico	∞ días (Fecha Actual – Fecha Indicada)	3
Días desde el Egreso	Numérico	∞ días (Fecha Actual – Fecha de Egreso)	1635

Fuente: Base de datos del Servicio de Medicina Interna del Hospital Las Higueras [6] y elaboración propia.

### 5.1.1 Generación de datos sintéticos

El diseño del nuevo conjunto combinó evidencia operativa y modelamiento estadístico. Primero se cuantificó la capacidad real de atención de los policlínicos a partir de la disponibilidad de box, bloques horarios y horas contratadas de cada médico. Y luego la proyección para someter el modelo de optimización a un escenario de estrés, estableciendo así una magnitud objetivo.

#### A. Dimensionamiento del conjunto

Para dimensionar el tamaño del conjunto de datos sintético, fue necesario realizar cálculos precisos sobre la disponibilidad física de los box de atención (Tabla 5.2), considerando los bloques horarios disponibles (Tabla 5.3), y la disponibilidad del personal médico (Tabla 5.4 y Tabla 5.5), teniendo en cuenta las horas de trabajo contractuales, para cuantificar la capacidad real de atención y así tener la cantidad de datos correcta para la validación del modelo.

Tabla 5.2. Disponibilidad de bloques horarios

Días	Bloques horarios diarios	Bloques horarios semanales	Bloques horarios mensuales
Lunes – Jueves	18	72	288
Viernes	16	16	64
<b>TOTAL</b>	34	88	<b>352</b>

Fuente: Agenda de policlínicos y elaboración propia.

Tabla 5.3. Disponibilidad física de atenciones por bloques horarios y box

Días	Bloques horarios mensuales	Boxes disponibles	Atenciones mensuales
Lunes - Jueves	288	13	3.744
Viernes	64		832
<b>TOTAL</b>	352	13	<b>4.576</b>

Fuente: Agenda de policlínicos y elaboración propia.

Tabla 5.4. Disponibilidad de médicos y sus horarios. Policlínico 1, Broncopulmonar

Médicos	Horas máximas de trabajo semanales	Duración del bloque de control post alta (horas)	Bloques de atención permitidos por doctor a la semana	Bloques de atención permitidos por doctor al mes
D1	4.5	0.5	9	36
D2	11		22	88

<b>D3</b>	7		14	56
<b>D4</b>	2		4	16
<b>TOTAL</b>	24.5	0.5	49	<b>196</b>

Fuente: Agenda de policlínicos y elaboración propia.

**Tabla 5.5. Disponibilidad de médicos y sus horarios. Policlínico 2, Gastroenterología**

<b>Médicos</b>	<b>Horas máximas de trabajo semanales</b>	<b>Duración del bloque de control post alta (horas)</b>	<b>Bloques de atención permitidos por doctor a la semana</b>	<b>Bloques de atención permitidos por doctor al mes</b>
<b>D1</b>	1.5	0.5	3	12
<b>D2</b>	4		8	32
<b>D3</b>	1		2	8
<b>D4</b>	7		17	68
<b>D5</b>	2		4	16
<b>D6</b>	1		2	8
<b>D7</b>	2		4	16
<b>D8</b>	10		20	80
<b>TOTAL</b>	24.5		0.5	57

Fuente: Agenda de policlínicos y elaboración propia.

## **B. Elaboración**

El conjunto sintético se diseñó partiendo de la capacidad operativa real de los dos policlínicos con mayor demanda post-alta (Broncopulmonar y Gastroenterología). Con 424 bloques horarios mensuales disponibles, la normativa obliga a reservar el 35% para primeras consultas, dejando 276 bloques horarios para controles. Para someter el modelo de agendamiento a un escenario de estrés se incrementó esta demanda en 30%, de modo que la cohorte objetivo quedó fijada en 358 episodios.

Sobre la base clínica original (266 episodios) y los egresos abiertos del DEIS 2020-2022 se estimaron distribuciones empíricas de: (i) tramo etario, (ii) policlínico, (iii) mes de egreso, (iv) número de diagnósticos y (v) días de hospitalización. Con Python 3.11 se generó el conjunto en 8 pasos:

- Muestreo de tramo etario con la pirámide observada.
- Asignación de policlínico aplicando la fracción histórica de la cohorte original (Broncopulmonar vs Gastroenterología).
- Sorteo del mes de egreso según la estacionalidad empírica.
- Selección del número de diagnósticos con su distribución suavizada; muestreo sin reemplazo de códigos CIE-10 a partir de la matriz edad-diagnóstico.
- Cálculo de tiempo recomendado a control. La media diagnóstico-edad más un ruido uniforme de  $\pm 5$  días, conservando el menor tiempo cuando hay diagnósticos múltiples.
- Creación de fecha de control sumando el tiempo anterior a la fecha de egreso, verificando que estuviera dentro de la ventana.
- Exportación automática a Google Sheets/Drive para trazabilidad.

De esta manera se garantizó un conjunto de datos representativo de las condiciones que se enfrentan en la realidad.

## 5.2. Priorización de episodios - SBR

La asignación de citas se apoyó en dos pilares: (i) el uso eficiente de los recursos disponibles y (ii) la jerarquización objetiva de los pacientes. Para ello se implementó un SBR que otorga a cada episodio un puntaje de prioridad a partir de 5 variables clave: edad, gravedad del diagnóstico de egreso, etapa GES, días transcurridos desde el alta y retraso respecto de la fecha ideal del control. Estas se detallan en la Tabla 5.6.

Las dimensiones y criterios de priorización fueron los siguientes:

- **Clínica:**

- *Pacientes con enfermedades con gravedad alta, media o baja:* una clasificación preliminar realizada en función de la generalidad de la enfermedad y nivel de gravedad de esta, considerando aspectos de letalidad, capacidad de transmisión, existencia de vacunas, tratamientos efectivos, etc.
- *Pacientes con fecha de controles determinados:* corresponde cuando se requiere una atención en una temporalidad específica indicada por el médico.

- **Demográfica:**

- *Pacientes adultos en grupos etarios:* se consideran grupos etarios diferentes, ya que a medida que la edad avanza, la salud se vuelve más inestable y se tiende a ser más vulnerable a ciertas enfermedades o complicaciones que otros.

- *Pacientes GES*: los que forman parte del sistema de Garantías Explícitas en Salud, lo que les permite el acceso oportuno y de calidad para ciertos contextos en salud.
- **Histórica:**
  - *Pacientes que aún no se les ha podido concretar el agendamiento*: cuando no se ha tenido éxito para agendar una cita o aún no se lleva a cabo la coordinación para esta.

**Tabla 5.6. Tipo de reglas del SBR a implementar**

<b>Tipo de Regla</b>	<b>Descripción</b>	<b>Ejemplo</b>
<b>Reglas de Producción</b>	Reglas que siguen la forma condicional clásica de 'si X, entonces Y'. Se utilizan para asignar puntajes según condiciones específicas, como la asignación de prioridad si el paciente no tiene policlínico. También categorizan variables como edad o días desde el alta en rangos numéricos.	Asignación de puntaje de prioridad a pacientes sin policlínico, 0. Asignación de puntaje por rangos de edad (18-24 = 1, 25-44 = 2, etc.).
<b>Reglas Heurísticas</b>	Reglas basadas en suposiciones prácticas que no garantizan una solución perfecta, pero proporcionan un método razonable para calcular puntajes.	Cálculo de prioridad basado en días desde el alta: mayor urgencia con el tiempo transcurrido a la fecha de control.
<b>Reglas de Inferencia Lógica</b>	Reglas que combinan métricas para llegar a un puntaje final.	Suma de puntajes de urgencia, etapa GES, edad y hospitalización para obtener el puntaje total de prioridad.
<b>Reglas de Control</b>	Reglas que determinan el flujo del proceso de cálculo, estableciendo el orden en el que se aplican las reglas. El factor de ajuste logarítmico es una regla de control que regula cómo se ajustan los puntajes en función del número de diagnósticos del paciente.	Factor de ajuste logarítmico basado en el número de diagnósticos válidos para ajustar los puntajes finales de los pacientes más complejos.

**Fuente:** Elaboración propia a partir de [36].

Estas variables se transformaron en valores numéricos simples mediante un proceso de mapeo, lo que facilita los cálculos de priorización.

Un mismo episodio podía incluir varios diagnósticos de egreso ( $n_{diag}$ ), lo que aumentaría tanto el puntaje de urgencia, como el de etapa GES. Para evitar un sesgo desproporcionado se aplicó un factor de ajuste logarítmico:

$$Factor = \frac{\ln(n_{diag} + 1)}{\log(10)} + 1 \quad (5.1)$$

Esta técnica estabiliza la varianza y reduce la influencia de los valores extremos, modera el crecimiento exponencial al pasar de pocos a muchos diagnósticos y garantiza que el factor nunca sea menor que 1 (cuando  $n_{diag} = 0$ ). El puntaje combinado de Urgencia y Etapa GES se divide por ese factor antes de sumarse al total ( $P_i$ ), de modo que los episodios con muchos diagnósticos no reciben ventaja injustificada. Las demás variables, como la edad, días de hospitalización, días desde el alta y los días hasta la fecha de control, también recibirán un puntaje el cual será sumado al puntaje de prioridad según los rangos de la Tabla 5.7, donde se pueden ver también ejemplos.

Primero se verifica que el policlínico asignado sea válido, de lo contrario el episodio recibe  $P_i = 0$ . Así, la suma final de puntaje para episodios válidos está dado por la expresión:

$$P_i = \frac{Urgencia_i + Etapa GES_i}{F_i} + \text{puntuajes de las demás variables según rango} \quad (5.2)$$

**Tabla 5.7. Valores y ejemplos de variables para el cálculo del Puntaje de Prioridad**

Variable	Valores	Ejemplo
<b>Etapa GES</b>	Mapeo: 'Ninguno' y 'No Aplica' = 0, 'Caso en Proceso' y 'Caso en Proceso Diagnóstico' = 1, 'Caso en Seguimiento', 'Caso en Tratamiento', y 'Caso Confirmado' = 2.	'Caso Confirmado' = 2.
<b>Urgencia/Gravedad</b>	Mapeo: 'Ninguno' = 0, 'BAJA' = 1, 'MEDIA' = 2, 'ALTA' = 3.	'ALTA' = 3.
<b>Edad (años)</b>	18 - 24 = 1; 25 - 44 = 2; 45 - 64 = 3; 64+ = 4.	Edad = 35 años; puntaje 2.
<b>Días de Hospitalización (días)</b>	0 - 3 = 1; 4 - 7 = 2; 8 - 14 = 3; 14+ = 4.	Días hospitalizado = 14; puntaje 4.
<b>Días desde el Egreso (días)</b>	0 - 7 = 1; 8 - 14 = 2; 15 - 30 = 3; 30+ = 4.	Días desde el egreso = 21; puntaje 3.
<b>Días para Fecha Indicada (días)</b>	31+ = 1; 15 - 30 = 2; 8 - 14 = 3; 0 - 7 = 4;  -7 - 0 = 5 (retraso leve); -14 - -8 = 6 (retraso moderado); -30 - -15 = 7 (retraso); -60 - -30 = 8 (retraso crítico); -60+ = 9 (retraso crítico).	Días hasta fecha indicada = 10; puntaje 3.
<b>Factor de ajuste Logarítmico</b>	Calculado como (5.1). Ajusta el puntaje para evitar crecimiento exponencial con múltiples diagnósticos	3 diagnósticos; Factor de ajuste» 1.602.
<b>Puntaje total diagnósticos</b>	Suma de puntajes de urgencia y etapa GES, dividido por el factor de ajuste logarítmico.	Urgencia = 3, Etapa GES = 2, Factor de ajuste» 1.602; Puntaje» 3.12.
<b>Control no Requerido (condición)</b>	Si el policlínico es 'Ninguno', el puntaje de prioridad es 0.	Policlínico = 'Ninguno'; Puntaje de Prioridad = 0.

Fuente: Elaboración propia.

Cada una de estas operaciones representa una regla lógica del sistema. Cuando se cumple la condición, se completa la acción correspondiente para asignar un puntaje específico de prioridad.

El sistema se implementa en Python 3.11, que ofrece la versatilidad necesaria para los cálculos y la integración con Google Sheets/Drive mediante la API v4 (OAuth 2.0). De esta manera, los episodios se importaron, priorizaron automáticamente y se exportaron incluyendo al puntaje  $P_i$  para incorporarlo en la función objetivo del MILP.

### **5.3. Algoritmo de optimización - MILP**

La metodología propuesta maximiza la atención de los pacientes con mayor prioridad, empleando de forma eficiente los recursos disponibles (médico, box y bloques horarios) y respetando todas las restricciones operativas del servicio. A continuación, se detalla el levantamiento de información para el modelo, la definición del umbral de prioridad, la formulación del modelo MILP, la calibración de pesos y la validación en distintos escenarios.

#### **5.3.1 Levantamiento de información**

Los elementos operativos sobre el proceso de agendamiento de los políclínicos, horarios de atención, personal disponible, etc., se levantaron a través de observación directa y entrevistas al personal del Servicio de Medicina Interna del Hospital Las Higueras para la construcción del modelo de optimización, centrado en el agendamiento de controles post-alta.

Primero, se realizaron dos videos conferencias con el doctor jefe del Servicio de Medicina Interna, lo que permitió comprender la problemática existente y luego, se llevaron a cabo visitas presenciales al hospital para observar in situ cada etapa, desde la preparación del alta hasta la inserción final de los episodios en las agendas. Previo a las visitas, se elaboró un cuestionario (ver Tabla 5.8), dirigido al personal relacionado con el agendamiento en la interconsulta de Medicina Interna. El propósito de este instrumento fue conocer el tipo de priorización existente de episodios, cantidad de policlínicos, box y médicos disponibles, así como los flujos administrativos involucrados, para la formulación del modelo y los algoritmos.

**Tabla 5.8. Preguntas para el Levantamiento del Proceso**

Pregunta	Respuestas
1. ¿Se pueden pedir citas para consultas ambulatorias en el mesón de interconsulta?	No, las citas solo se les dan a pacientes dados de alta de Medicina Interna o derivados del mismo hospital.
2. Para el agendamiento, ¿hay diferencias entre un paciente ambulatorio y un paciente que estuvo hospitalizado?	No existen diferencias para el agendamiento, se les trata como iguales.
3. ¿Hay algún horario especial para atención de los pacientes que estuvieron hospitalizados?	Doctor: No, pero hay diferencias en los tipos de consultas que existen. Secretarias: No hay horarios especiales, quedarán categorizados como "consulta repetida" y eso no cambia en nada.
4. Cuando se agendan a los pacientes, ¿hay algún tipo de priorización?	No.
5. ¿Cómo son las jornadas de atención?	Cada doctor tiene su propia agenda; el servicio de la interconsulta se encuentra abierto de lunes a jueves de las 8 am a 5 pm y los viernes de 8 am a 4 pm.
6. ¿Los horarios de los médicos son iguales siempre?	Los horarios de cada uno de los médicos se repiten semanalmente.

7. ¿Cómo son las duraciones de los controles?	Las duraciones de los controles nuevos duran 45 minutos, mientras que los controles repetidos duran 30 minutos. Existe un policlínico que posee un bloque de horas llamado "consulta abreviada" para verificar si vale la pena atender al paciente ya que la lista es espera de este policlínico es muy grande, este es el de Medicina Interna.
---	---

Fuente: [6].

Los principales puntos extraídos fueron:

- **Ausencia de priorización explícita.** Todos los pacientes (ambulatorios o post-alta) se gestionan con la misma lógica "primer bloque disponible". Un ejemplo de agenda se muestra en la Tabla 5.9.

Tabla 5.9. Ejemplo de tabla de un Policlínico del documento Excel

Estado de respuesta	Fecha para la consulta	Nombre	RUT	Fecha del alta	Exámenes	Prioritario
PEN-DIENTE	09/11	Nombre1 Apellido1	12.345.678- 1	01/10	NO RE-QUIERE	
ENTRE-GADA	07/11	Nombre2 Apellido2	12.345.678- 2	01/10	NO RE-QUIERE	PRIORITA-RIO
NO CON-TESTA	07/11	Nombre3 Apellido3	12.345.678- 3	10/10	REQUIERE	

Fuente: [6].

- **Duración diferenciada de controles.** Las consultas nuevas duran 45 min, las repetidas, incluidas las post-alta, 30 min., ver Tabla 5.10 para mayor detalle. Existe además un bloque "consulta abreviada" exclusivo de Medicina Interna.

**Tabla 5.10. Tipos de consultas de la interconsulta de Medicina Interna**

Tipo de Consulta	Duración (minutos)	Observación
Consulta Nueva	45	-
Consulta Repetida	30	Contempla a Consulta Repetida General, Repetida Restringida y Post-Alta

Fuente: [6].

- Actualización mensual de listas de espera.** Alrededor del día 20 se revisa la lista y se contacta telefónicamente a los pacientes; tras 3 intentos fallidos, el caso se cataloga como “no contestó” y se reprograma con prioridad el mes siguiente.
- Capacidad instalada.** El servicio dispone de 17 box (4 reservados para Neurología), 51 médicos actualmente distribuidos en 13 policlínicos, con cargas semanales heterogéneas como se ve en la siguiente Tabla 5.11.

**Tabla 5.11. Policlínicos y Médicos en el Servicio de Medicina Interna**

Policlínico	Cantidad de Médicos	Disponibilidad de horas semanales
Medicina Interna	2	Doctor 1 = 2 Doctor 2 = 11
Gastroenterología	8	Doctor 1 = 1.5 Doctor 2 = 4 Doctor 3 = 1 Doctor 4 = 7 Doctor 5 = 2 Doctor 6 = 1 Doctor 7 = 2 Doctor 8 = 10

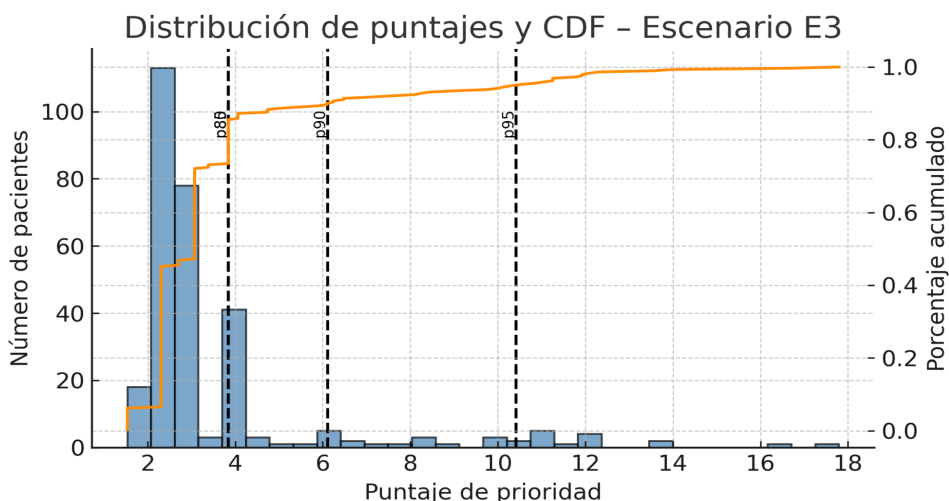
<b>Reumatología</b>	7	Doctor 1 = 11 Doctor 2 = 6 Doctor 3 = 11.5 Doctor 4 = 8 Doctor 5 = 1 Doctor 6 = 5 Doctor 7 = 2
<b>Cardiología</b>	1	Doctor 1 = 3.5
<b>Endocrinología</b>	3	Doctor 1 = 3.5 Doctor 2 = 4 Doctor 3 = 13
<b>Diabetes</b>	3	Doctor 1 = 3 Doctor 2 = 12 Doctor 3 = 11
<b>Nefrología</b>	1	Doctor 1 = 4.5
<b>Broncopulmonar</b>	4	Doctor 1 = 4.5 Doctor 2 = 11 Doctor 3 = 7 Doctor 4 = 2
<b>Infectología</b>	1	Doctor 1 = 5
<b>Inmunología</b>	1	Doctor 1 = 4
<b>Geriatría</b>	2	Doctor 1 = 2 Doctor 2 = 10
<b>Hematología</b>	3	Doctor 1 = 6 Doctor 2 = 13 Doctor 3 = 6
<b>Oncología</b>	3	Doctor 1 = 6 Doctor 2 = 6 Doctor 3 = 12

Fuente: [6].

Esta caracterización permitió definir restricciones de capacidad, horizontes de planificación y parámetros de duración para el modelo.

### 5.3.2 Umbral de prioridad de pacientes

Para reservar los bloques horarios de los polínicos a los casos de mayor puntaje, fue necesario fijar un punto de corte objetivo en la distribución de los puntajes. Así, para cada escenario de validación, definidos en el apartado 5.4.1, se extrajeron los puntajes de los pacientes a agendar y se calculó tanto el histograma como la función de distribución acumulada (CDF), al mismo tiempo que los percentiles p80, p85, p90 y p95. La Ilustración 5.2 muestra, como ejemplo para el escenario E3, el histograma de puntajes (barras azules) y la CDF (línea naranja), y con líneas punteadas se marcan los percentiles analizados. Los demás gráficos de distribución de puntajes y CDF pueden verse en el Anexo B.



**Ilustración 5.2. Distribución de puntajes y CDF - E3.**

**Fuente:** Elaboración propia.

La Tabla 5.12 resume, para los escenarios, los valores de los percentiles y la porción de pacientes que quedarían clasificados como Alta Prioridad con cada corte.

**Tabla 5.12. Percentiles y porción de pacientes clasificados como Alta Prioridad**

Escenario	P80	P85	P90	P95	% $\geq P90$
E1	3.07	3.84	3.84	9.19	18.1
E2	3.07	3.84	3.84	9.19	18.1
E3	3.84	3.84	6.11	10.41	10
E4	3.84	3.84	6.03	10.27	10.2
E5	3.84	3.84	5.6	10.16	10.1
E6	3.84	3.84	4.99	10.06	10.3
E7	3.84	3.84	4.74	9.82	10.4
E8	3.84	4.06	6.45	10.82	10.3
E9	3.84	4.06	6.65	10.97	10.1
E10	3.84	4.74	7.38	11.1	10.2
E11 → E14	3.84	4.01	6.24	10.59	10.5

**Fuente:** Elaboración propia.

De la tabla se puede ver que, aunque los percentiles p80 y p85 se mantienen estables, ambos caen en una zona plana de la CDF que no posee un punto de inflexión claro para diferenciar los niveles de urgencia. Por otro lado, p95 se ubica en una posición extrema de la distribución, clasificando únicamente al 5%

de más prioritario. Este recorte es muy restrictivo y resulta poco práctico y sensible a variaciones en los datos, lo que generaría umbrales volátiles en los demás escenarios. En cambio, p90 identifica con mayor precisión la transición hacia los pacientes de mayor prioridad, delimitando al ~10% superior, y apenas varía incluso cuando el número se reduce.

Es por ello por lo que se elige el percentil 90 como umbral por las siguientes razones:

- **Cambio en la pendiente de la CDF:** En la mayoría de los escenarios, la curva de la CDF muestra un punto de inflexión entre el puntaje de prioridad 6 y 7, zona en la que se sitúa el p90.
- **Estabilidad numérica:** El p90 oscila entre 6 y 7.4 puntos de prioridad entre los escenarios y nunca desciende por debajo de los 5 puntos, lo que garantiza que incluso en situaciones de baja exigencia, el umbral se mantiene pudiendo aplicar una regla homogénea para todos los escenarios sin tener que volver a calibrar en cada uno de ellos el umbral.
- **Simplicidad operativa:** El percentil p90 se calcula de forma automática en cada escenario, asegurando reproducibilidad y evitando ajustes manuales entre escenarios.

En resumen, este percentil marca un punto de inflexión más estable para priorizar los recursos en los escenarios.

### 5.3.3 Formulación

El modelo MILP se estructuró en torno a las siguientes componentes, desde la Tabla 5.13 hasta la Tabla 5.15:

**Tabla 5.13. Conjuntos del modelo MILP**

Símbolo	Descripción
$\mathbb{I}$	Pacientes post-alta a agendar
$\mathbb{D}$	Médicos disponibles
$\mathbb{M}$	Días del horizonte ( $M = 20$ días hábiles)
$\mathbb{H}(m)$	Bloques de 30 min del día $m$ (18 lun-jue, 16 vie)
$\mathbb{B}$	Box, $B=13$
$\mathbb{S}(i)$	Médicos cuya especialidad atiende al paciente $i$

Fuente: Elaboración propia.

**Tabla 5.14. Parámetros del modelo MILP**

Parámetro	Descripción
$P_i \in [0,100]$	Puntaje de prioridad del paciente $i$ .
$f_i$	Día ideal de control que indica el médico (día absoluto).
$w_i$	Ventana días $\pm$ permitidos si $i$ es prioritario.
$HMAX_d$	Horas máximas de trabajo del médico $d$ .
$RES$	Fracción máxima de bloques destinados a post-alta (0.65).
$bonus\_pat$	Bonificación por asignación de paciente $i$ .
$bonus\_doc$	Bonificación por asignación de médicos cuya especialidad atiende al paciente $i$
$pen\_noH$	Penalización por pacientes prioritarios sin cita.
$pen\_noL$	Penalización por pacientes no prioritarios sin cita.

$pen\_delay\_hi$	Penalización por día de retraso de paciente prioritario.
$pen\_delay\_lo$	Penalización por día de retraso de paciente no prioritario.
$pen\_idle$	Penalización bloque ocioso.
$w\_eq$	Peso de la desigualdad horaria entre médicos.

Fuente: Elaboración propia.

**Tabla 5.15. Variables de decisión del modelo MILP**

Tipo	Símbolo	Descripción
<b>Binarias</b>	$P[i, m, h, b]$	Asigna al paciente $i$ en el día $m$ , bloque $h$ y box $b$ . (1) si el paciente $i$ ocupa el bloque $(m, h, b)$ , o no (0).
	$D[d, m, h, b]$	Asigna al doctor $d$ al bloque $h$ en el día $m$ en el box $b$ (1) si el médico $d$ atiende el bloque $(m, h, b)$ , o no (0).
	$A[i]$	Indica si el paciente $i$ ha sido agendado (1) o no (0).
	$Idle[m, h, b]$	Indica si el bloque $h$ del día $m$ en el box $b$ quedó vacío (1) o no (0).
<b>Continuas</b>	$Delay[i]$	Número de días de retraso respecto a $f_i$ , la fecha indicada del paciente $i$ .
	$Hdoc[d]$	Horas totales trabajadas por el doctor $d$ .
	$\mu$	Media de horas trabajadas entre todos los médicos.
	$\Delta_d$	Desviación absoluta de $d$ respecto a $\mu$ .

Fuente: Elaboración propia.

La función objetivo integró términos con pesos ponderados ( $W$ ) mencionados en la Tabla 5.14, buscando maximizar el cumplimiento clínico y operativo, estos fueron:

- Bonificación por asignar pacientes ( $bonus_{pat}$ ) y médicos ( $bonus_{doc}$ ).
- Penalizaciones por dejar pacientes sin agendar ( $pen_{noL}$ ), especialmente si son prioritarios ( $pen_{noH}$ ).
- Penalizaciones por retraso (diferencia según prioridad) ( $pen_{delay_{hi}}, pen_{delay_{lo}}$ ).
- Penalización por ociosidad ( $pen_{idle}$ ) y desigualdad en la carga horaria entre médicos ( $w_{eq}$ ) medida como la desviación absoluta respecto a la media.

Y las restricciones, las siguientes:

- Cada paciente puede ser agendado solo una vez.

$$A_i = \sum_{m,h,b} P_{i,m,h,b} \leq 1 \quad \forall i \in \mathbb{I}$$

- Cada box admite un solo paciente y médico por bloque.

$$\sum_i P_{i,m,h,b} \leq 1, \quad \sum_d P_{i,m,h,b} \leq 1 \quad \forall m, h, b$$

- Los pacientes solo pueden ser asignados a médicos de la especialidad correspondiente.

$$P_{i,m,h,b} \leq \sum_{d \in S(i)} D_{d,m,h,b} \quad \forall i, m, h, b$$

- Las horas máximas por doctor no pueden ser superadas ( $HMAX_d$ ).

$$Hdoc_d = 0.5 \sum_{m,h,b} D_{d,m,h,b}, \quad Hdoc_d \leq HMAX_d \quad \forall d \in \mathbb{D}$$

- Reserva máxima del 65% de los bloques horarios disponibles para post-alta.

$$\sum_i P_{i,m,h,b} \leq RES \quad \forall m, h, b$$

- Para pacientes prioritarios ( $\geq 90$ ), solo se permite agendamiento dentro de una ventana clínica.

$$P_{i,m,h,b} = 0 \text{ si } m \notin [f_i - w_i, f_i + w_i] \quad \forall i \text{ con } P_i \geq 90$$

- Cálculo de retraso

$$Delay_i \geq (m - f_i) P_{i,m,h,b} \quad \forall i, m, h, b$$

- Bloques ociosos

$$Idle_{m,h,b} \geq \sum_d D_{d,m,h,b} - \sum_i P_{i,m,h,b}, \quad 0 \leq Idle_{m,h,b} \leq 1$$

- Media y desigualdad de horas médicas

$$\mu = \frac{1}{|\mathbb{D}|} \sum_d Hdoc_d, \quad \Delta_d \geq Hdoc_d - \mu, \Delta_d \geq \mu - Hdoc_d \quad \forall d$$

- Dominio de variables

$$P, D, A, Idle \in \{0,1\}, Delay, Hdoc, \mu, \Delta \geq 0$$

Finalmente, la función objetivo la siguiente:

$$\begin{aligned}
\max Z = & \sum_{i,m,h,b} \left( \frac{P_i}{100} \right) P_{i,m,h,b} + \text{bonus\_pat} \sum_i A_i \\
& + \text{bonus\_doc} \sum_{d,m,h,b} D_{d,m,h,b} \\
& - \text{pen\_noH} \sum_{i:P_i \geq p90} (1 - A_i) \\
& - \text{pen\_noL} \sum_{i:P_i < p90} (1 - A_i) \\
& - \text{pen\_delay\_hi} \sum_{i:P_i \geq p90} \text{Delay}_i \\
& - \text{pen\_delay\_lo} \sum_{i:P_i < p90} \text{Delay}_i \\
& - \text{pen\_idle} \sum_{m,h,b} \text{Idle}_{m,h,b} \\
& - w\_eq \sum_d \Delta_d, \quad \text{con } \mu = \frac{1}{|\mathbb{D}|} \sum_d Hdoc_d.
\end{aligned} \tag{5.3}$$

#### 5.3.4 Horizonte y estructura temporal de la planificación

El horizonte de planificación fue de 20 días hábiles consecutivos. Cada jornada se compuso en bloques horarios de 30 minutos:

- 18 bloques horarios (9 h) de lunes a jueves.
- 16 bloques horarios (8 h) los viernes.

Con 13 box disponibles, el número teórico de bloques fue de 4.576. No obstante, los 12 especialistas (de los 2 policlínicos seleccionados) sumaron 424 blo-

ques máximos de atención, límite real que el modelo no debía sobrepasar. Además, solo el 65% (276 bloques) se habilitó para controles post-alta, el resto quedó reservado para primeras consultas.

### 5.3.5 Ajustes del algoritmo

Durante la validación del modelo MILP (escenarios E2-E14) se ajustó progresivamente la matriz de pesos  $W$  presente en la función objetivo (5.3) del modelo. La Tabla 5.16 muestra la evolución de cada parámetro desde el prototipo inicial hasta la versión estable.


Durante la implementación y validación del modelo MILP se identificó la necesidad de ajustar iterativamente los pesos ( $W$ ) que controlan el comportamiento de la función objetivo, a base de los resultados de los escenarios de validación. Estos pesos determinaron las prioridades implícitas del modelo, y pequeños cambios en su magnitud afectaban significativamente la solución óptima. A continuación, se detalla la evolución de estos parámetros desde el prototipo inicial hasta la versión estable utilizada en los escenarios de validación.

**Tabla 5.16. Ajustes aplicados a la matriz de pesos del modelo MILP**

Parámetro	Inicio	Final	Justificación
$wH (\geq p90)$	0.75	1	Aumentar presión para agendar pacientes prioritarios, que estaban quedando sin turno.
$wL (< p90)$	0.5	0.3	Permitir que el modelo omita pacientes de menor prioridad en contextos restrictivos.
$bonus\_pat$	0.75	1	Incentivar cobertura total cuando había disponibilidad.
$bonus\_doc$	0.6	0.3	Evitar que se llenen turnos poco productivos solo

			por sumar puntos en la función objetivo.
<i>pen_noH</i>	0.75	<b>1</b>	Penalizar fuertemente la omisión de pacientes prioritarios.
<i>pen_noL</i>	0.75	<b>0.4</b>	Permitir omitir pacientes no prioritarios sin castigo excesivo.
<i>pen_dely_hi</i>	0.002	<b>0.004</b>	Reducir retrasos medios en pacientes críticos, detectados como $\geq 4$ días.
<i>pen_delay_lo</i>	0.0005	<b>0.001</b>	Mantener proporción 4:1 en penalización de retrasos entre pacientes críticos y no críticos.
<i>pen_idle</i>	0.002	<b>0.001</b>	Permitir bloques vacíos razonables, evitar que el solver prefiriera dejar pacientes sin cita solo para evitar ociosidad.
<i>w_eq</i>	-	<b>0.08</b>	Suavizar desigualdades en carga horaria entre médicos.

Fuente: Elaboración propia.



Los cambios se guiaron por 3 indicadores clave: (i) Cobertura de pacientes ( $\geq p90$ ), (ii) retraso medio respecto a la fecha indicada y (iii) distribución de carga horaria entre médicos. Cada iteración se validó con los KPIs complementarios; al detectar un sesgo, se reajustaron las penalizaciones y bonificaciones hasta lograr el equilibrio deseado.

Como parte del proceso de desarrollo y ajuste del modelo, se exploró una variante de formulación que introdujo una ventana clínica extendida de  $\pm 5$  días para pacientes prioritarios (aquellos con puntaje superior al percentil 90). Esta modificación permitía agendar a dichos pacientes dentro de un rango más amplio alrededor de su fecha indicada, en lugar de exigir una coincidencia exacta. El objetivo teórico era aumentar la probabilidad de encontrar espacios disponibles

para los casos más críticos, especialmente en situaciones donde la disponibilidad de bloques horarios era limitada, sin aumentar el uso de recursos.

Desde el punto de vista del diseño, se pretendió ajustar la restricción de ventana clínica, habilitando el uso de bloques horarios en un margen de cinco días antes o después de la fecha indicada.

Aunque los efectos de esta variable fueron evaluados en la fase de validación, en escenarios de alta presión, el modelo desplazó fuera de agenda a muchos pacientes de baja prioridad para cumplir con esta nueva restricción, reduciendo la cobertura global a un rango de 64-76%, a pesar de mantener el uso total de horas y box. Confirmando que la aplicación de la ventana clínica para casos graves mejora la oportunidad de atención solo cuando existe suficiente holgura. En condiciones de congestión, el costo en cobertura general es demasiado alto, por lo tanto, se descartó esta variante de la versión final para el modelo.

#### **5.4. Validación del sistema**

La validación del sistema se centró en dos aspectos fundamentales: la priorización efectiva de los episodios más urgentes y la eficiencia en el uso de los recursos hospitalarios. El objetivo fue garantizar que el sistema priorice correctamente a los episodios con mayor puntaje de prioridad, maximizando el número de estos que son atendidos dentro de los recursos disponibles (médicos, boxes y horarios), y asegurando un uso óptimo de recursos.

Para medir el éxito del sistema, se utilizaron las siguientes métricas generales:

- **Número de episodios con alta prioridad atendidos:** cuántos episodios con los puntajes de prioridad más elevados fueron asignados a citas en los policlínicos. Esto permite verificar si el modelo logra priorizar de manera efectiva a los episodios más críticos.
- **Promedio de puntajes de los pacientes atendidos:** es el promedio de los puntajes de prioridad de los pacientes agendados, para evaluar si el modelo favorece consistentemente a aquellos con mayor necesidad.
- **Utilización de recursos:** mide la tasa de utilización de médicos y boxes, y se analizan los tiempos muertos entre citas para verificar si el modelo distribuye eficientemente los recursos disponibles.
- **Número de pacientes no agendados:** analiza cuántos pacientes no lograron ser agendados al final de cada ciclo de planificación. Esto permite identificar cuellos de botella y evaluar si el modelo necesita ajustes en las restricciones o en la extensión de los ciclos.

Estas métricas permitieron evaluar no solo si el modelo priorizaba correctamente a los pacientes más críticos, sino también si se asignaban los recursos de manera eficiente y asegurar que los pacientes recibían la atención adecuada en función de su necesidad.

### 5.4.1 Escenarios de evaluación

Para evaluar el comportamiento del modelo de optimización bajo condiciones realistas y diversas, se definieron 14 escenarios de simulación (E1 a E14), agrupados según el tipo de estrés que presentan. Esta estrategia responde a la necesidad de probar el modelo frente a tres fuentes clave de variabilidad: la política de asignación actual (E1-E2), la variación progresiva en la demanda de pacientes (E3-E10) y la reducción escalonada de la capacidad médica disponible (E11-E14).

Estas dimensiones fueron seleccionadas porque representan situaciones habituales en el contexto hospitalario real, como aumentos de egresos hospitalarios, licencias médicas o reorganización de turnos. Simular estos casos permite poner a prueba la flexibilidad y robustez del modelo frente a distintos niveles de presión asistencial o restricciones operativas. Además, dado que no es posible intervenir directamente en el entorno clínico real, la simulación se convierte en la única vía factible para observar el desempeño del modelo bajo condiciones controladas pero representativas.

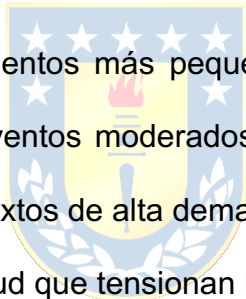
La descripción detallada de cada escenario se presenta en la Tabla 5.17, y su agrupación en la Tabla 5.18. A continuación, se detallan sus principales características:

- **Sistema Simplificado (Orden GES + FIFO):** Este escenario E1 replica la lógica actual de asignación, donde se prioriza a pacientes GES y luego se

aplica un criterio de orden de llegada (FIFO: *First In, First Out*). Sirve como línea base para comparar los beneficios del modelo propuesto.

- **Sistema MILP:**

- *Escenario Base (E2)*: se aplica el modelo MILP a las condiciones del Sistema Simplificado (E1), es decir, misma cantidad de pacientes y recursos.
- *Escenario de Demanda (E3-E10)*: se varía la cantidad de pacientes en  $\pm 5\%$ ,  $\pm 10\%$ ,  $\pm 15\%$ , y  $+30\%$ , manteniendo constantes los recursos.



Los incrementos más pequeños representan fluctuaciones estacionales o eventos moderados, mientras que el aumento del 30% simula contextos de alta demanda, como brotes epidémicos o campañas de salud que tensionan la capacidad del sistema.

Las disminuciones reflejan contextos de menor carga asistencial, ya sea por mejoras sanitarias o estrategias preventivas.

- *Escenario de Capacidad (E11-E14)*: se simulan reducciones progresivas de capacidad operativa en  $-5\%$ ,  $-10\%$ ,  $-15\%$  y  $-20\%$ , manteniendo constante la demanda.

Las reducciones de 5% y 10% por posibles ausencias temporales del personal o ajustes de turnos, 15% y 20% en el caso

de escenarios más severos, como licencias prolongadas, suspensión de recursos físico o algún otra causa.

La elección de estos porcentajes no fue arbitraria, se seleccionaron rangos plausibles según variaciones que se pueden observar en la salud, permitiendo evaluar el modelo de forma gradual y progresiva. Esta estrategia también permite identificar si es que existe algún umbral donde el modelo comience a perder eficiencia o cobertura, lo cual son aspectos clave para su aplicación práctica.



Tabla 5.17. Escenarios de evaluación del algoritmo de optimización

Escenarios				Pacientes	Bloques Horarios		
					Policlínico 1 Broncopulmonar	Policlínico 2 Gastroenterología	
E1	Sistema Simplificado (Orden GES + FIFO)			276	196	228	
E2	MILP	Base					
E3		Demanda	Alta	+ 5%			290
E4				+ 10%			304
E5				+ 15%			317
E6				+ 20%			331
E7				+ 30%			358
E8				Baja			
E9		- 10%	248				
E10		- 15%	235				
E11		- 5%	276				
E12		Capacidad	Bloques Horarios	- 10%			176
E13				- 15%			167
E14				- 20%			157
						186	

Fuente: Elaboración propia.

Tabla 5.18. Grupos de evaluación para evaluación del algoritmo de optimización

Grupo	Escenarios	Cambio Testeado
1	E1 vs E2	Demanda y capacidad idénticas.
2	E1 vs E3 → E7	Demanda creciente (+5% → +30%).
3	E1 vs E8 → E10	Demanda decreciente (-5% → -20%).
4	E1 vs E11 → E14	Recorte de bloques en policlínicos (-5% → -20%).

Fuente: Elaboración propia.

### 5.4.2 Métricas de validación

Estas métricas fueron empleadas para evaluar la calidad y eficiencia del agendamiento generado por el modelo MILP. Cada una de ellas aportó una perspectiva diferente sobre el desempeño como se describe a continuación en las Tabla 5.19 y Tabla 5.20:

**Tabla 5.19. Métricas de validación modelo MILP**

Métrica	¿Qué mide?	Detalle
<b>Cobertura (%)</b>	Proporción de pacientes efectivamente agendados.	Valida el objetivo primario: maximizar el acceso a citas. Valores cercanos al 100% indican mayor cantidad de atenciones, mientras que valores bajos pueden significar cuellos de botella o limitaciones de recursos.
<b>Episodios <math>\geq p90</math> (n)</b>	Número de pacientes con puntaje $\geq p90$ que reciben cita.	Indica la efectividad del modelo en priorizar los casos más urgentes. Comprueba que la regla de prioridad (atender a prioritarios) se respeta en los escenarios.
<b>Retraso medio (bloques)</b>	Diferencia promedio de bloques horarios (de 30 min) entre la fecha indicada y la cita asignada.	Retrasos altos indican fallos en la cobertura.
<b>Horas médicas utilizadas (h) (% de 218)</b>	Horas totales asignadas a médicos.	Permite verificar que la asignación de bloques horarios se ajusta a la disponibilidad contractual de los especialistas.
<b>Bloques utilizados (% de 276)</b>	Porcentaje de bloques reservados para post-alta (276) que el modelo ocupa.	Indica la eficiencia de los recursos físicos. Valores bajos implica capacidad ociosa y valores cercanos al 100% indican uso eficiente de la capacidad de asignación.

<b>Bloques ociosos</b>	Cantidad de bloques horarios que quedaron vacíos.	Calculados como la diferencia entre la disponibilidad máxima y los realmente utilizados.
<b>Holgura intra-día (bloques/día)</b>	Vacíos que quedan entre la primera y última cita de cada día.	Demasiada holgura en el horizonte temporal genera tiempos muertos y muy poca, retrasos.
<b>Puntaje medio diario</b>	Promedio del puntaje de los pacientes atendidos cada día.	Refleja el nivel de urgencia de las citas programadas a lo largo del horizonte.

Fuente: Elaboración propia.

**Tabla 5.20. KPIs complementarios de validación modelo MILP**

<b>Métrica</b>	<b>¿Qué mide?</b>	<b>Detalle</b>
<b>Delay p90</b>	Bloques que espera el 10% más atrasado de los pacientes agendados.	Mide la cantidad de bloques horarios (de 30 min) que deben esperar los pacientes con mayor retraso relativo, considerando el percentil 90 del retraso. Es útil para identificar si existen demoras críticas en una parte de la población atendida.
<b>Delay p95</b>	Bloques que espera el 5% más atrasado de los pacientes agendados.	Evalúa los retrasos más extremos en la programación de citas. Un valor muy alto indica que, aunque la mayoría fue agendada correctamente, unos pocos enfrentan demoras importantes.
<b>Adelantados / Retrasados</b>	N.º de pacientes citados antes o después de su fecha indicada.	Esta clasifica a los pacientes según si fueron citados antes o después de su "ventana clínica". Permite evaluar cuánto se ajusta el modelo a la fecha sugerida por el médico tratante.
<b>Desviación de horas por médico (h)</b>	Dispersión absoluta de horas asignadas entre los especialistas.	Cuantifica la inequidad en la carga horaria. Valores bajos indican que los médicos trabajan una cantidad de horas similar, lo cual es deseable en términos

		de equidad y eficiencia operativa. Se calcula como la suma de desviaciones absolutas respecto a la media.
--	--	---

**Fuente:** Elaboración propia.

El percentil 90 ( $p90$ ) se adopta como indicador principal para evaluar el extremo superior de la distribución de retrasos, dado que coincide con la métrica oficial utilizada por el Servicio de Salud Biobío para caracterizar los tiempos máximos de espera, así como la referencia empleada por Biblioteca del Congreso Nacional en sus estudios sobre rendición pública de listas de espera. Complementariamente, se reporta el percentil 95 ( $p95$ ) para analizar con mayor precisión los casos más extremos (~ 5 % superior de la cohorte), verificando así que la mejora en los tiempos de espera generales no implicaba un empeoramiento en los retrasos más prolongados.

### 5.5. Implementación computacional


La implementación se realizó en Python 3.11, utilizando la biblioteca PuLP para la formulación del modelo; la cual permitía resolver problemas de optimización mediante técnicas como la ramificación y corte (*branch-and-bound*), que se emplean para encontrar soluciones óptimas y el solver CBC como *backend* de resolución.

El modelo se ejecutó en un computador con 10 CPU lógicos, y se compararon 3 configuraciones del modelo MILP para determinar su impacto en los resultados, todos con gap de corte del 3%. La primera versión utilizó 4 hilos y tiempo

límite de 900 segundos, la segunda empleó 2 procesos simultáneos con 5 hilos cada uno y con el mismo tiempo límite, y la tercera empleó los mismos 2 procesos simultáneos pero ampliado el tiempo límite a 1500 segundos. Esta prueba buscó evaluar si el uso de más recursos computacionales o mayor tiempo permitía encontrar soluciones con mejores indicadores operativos o clínicos.

### 5.6. Arquitectura del sistema

Los módulos desarrollados incluyeron: carga de pacientes, generación estructurada de bloques horarios, definición de variables, formulación de la función objetivo y establecimientos restricciones operativas y clínicas. Finalizando el proceso, se exportaron archivos Excel con la agenda diaria optimizada y tableros de indicadores clave (KPIs), tales como cobertura, utilización efectiva de bloques horarios y desviación en la carga médica para la validación del modelo.



La arquitectura del sistema se organizó en los siguientes módulos clave:

- **Extracción de información:** encargado de extraer la información relevante de la base de datos.
- **Procesamiento de la información:** la información extraída se limpia y procesa para obtener lo elemental de esta y lo que es útil para la construcción del algoritmo.
- **Priorización de episodios:** utilizado para asignar un nivel de prioridad numérico a los episodios en función de su contexto médico post-alta.

Basado en SBR.

- **Modelo MILP:** definición de conjuntos, parámetros y variables de decisión para asignación de los episodios a los recursos específicos existentes. Además, de las fórmulas correspondientes, se integran los resultados de priorización del algoritmo de inteligencia artificial SBR.
- **Intercomunicación con APIs:** intercomunicación entre Python, Google Sheets, Google Drive de Google para almacenamiento de datos y su manipulación segura.

### 5.7. Criterios de evaluación de la hipótesis

La mejora se busca mediante la maximización del número de alta prioridad agendados dentro de su ventana clínica, el equilibrio de carga de trabajo médico, la reducción de retrasos y la disminución de la ociosidad en recursos físicos.

Para evaluar la hipótesis, se comparan los resultados con el método base (GES+FIFO) utilizando los indicadores de desempeño y KPIs definidos en la Tabla 5.19 y Tabla 5.20. La hipótesis se considerará validada si el modelo, en comparación con el método base, mantiene o incrementa la cobertura total, aumenta la proporción de episodios prioritarios agendados, mantiene o reduce retrasos, mejora la distribución de la carga médica y optimiza el uso de recursos físicos, sin requerir un aumento adicional de capacidad.

## **Capítulo 6. RESULTADOS**

---

### **6.1. Priorización de episodios**


La priorización de los episodios se llevó a cabo utilizando el Sistema Basado en Reglas (SBR), procesando un total de 266 episodios obtenidos mediante la base de datos facilitada por el Servicio de Medicina Interna del Hospital Las Higueras. Esta base incluyó registros de pacientes adultos dados de alta entre los años 2020 y 2022. Las variables consideradas para la priorización fueron: edad del paciente, gravedad del diagnóstico de egreso, días de hospitalización, etapa GES, días transcurridos desde el alta hospitalaria y retraso respecto a la fecha indicada para el control post-alta. Para aquellos episodios con múltiples diagnósticos, se registraron columnas adicionales para cada uno de estos junto a su respectiva etapa GES. Las variables mencionadas pueden verse en la Ilustración 6.1.

ID	Edad	Fecha de Egreso	Días de Hospitalización	Indicación Control post-alta	Policlínico	Temporalidad
9400636.pdf	79	28/09/2022	5	control policlinico nefrologia ...	Nefrología	segun disponibilidad
94003227.pdf	82	31/08/2020	11	control poli ucra 3 dias con ex...	Cardiología	segun disponibilidad
94005123.pdf	71	27/03/2020	1	reposo relativo regimen diabeti...	Ninguno	Ninguno
94005668.pdf	92	17/01/2020	21	1 reposo relativo asistido 2 re...	Ninguno	Ninguno
94006025.pdf	88	23/03/2022	11	control con nuevo perfil fierro...	Hematología	segun disponibilidad

ID	Días para agendar	Fecha Indicada	Días desde el Egreso	Días para Fecha Indicada
9400636.pdf	14	12/10/2022	646	-632
94003227.pdf	14	14/09/2020	1404	-1390
94005123.pdf	0	Ninguno	1561	0
94005668.pdf	0	Ninguno	1631	0
94006025.pdf	14	06/04/2022	835	-821


**Ilustración 6.1. Base de datos y algunas de sus variables.**



Cada variable se transformó en valores numéricos mediante el proceso de mapeo definido previamente. La edad fue categorizada en grupos etarios con puntajes incrementales para reflejar la mayor vulnerabilidad asociada al envejecimiento. La gravedad de los diagnósticos y las etapas GES se convirtieron en valores numéricos según su nivel de criticidad y seguimiento requerido. Por otra parte, variables temporales como los días desde el egreso y los días hasta la fecha indicada fueron puntuadas de manera proporcional a la urgencia clínica que representaban. En caso de pacientes con múltiples diagnósticos, se implementó el factor de ajuste logarítmico para evitar que el puntaje creciera despro-

porcionadamente debido al número de diagnósticos registrados. Este factor estabilizó la varianza de los puntajes reduciendo así la influencia excesiva de casos extremos y asegurando una distribución equilibrada y precisa del puntaje total.

El puntaje final de cada episodio ( $P_i$ ) se calculó sumando los valores ajustados de urgencia y etapa GES, junto con las demás variables mencionadas anteriormente. En episodios que no requerían agendamiento (policlínico asignado era “Ninguno” u otro fuera del Servicio o el paciente había fallecido), el puntaje fue fijado en 0, facilitando la exclusión automática en la programación de citas. Ejemplos de la conversión a valores numéricos para las variables de los episodios se ven representados en la Ilustración 6.2.



ID	Puntaje Prioridad	Puntaje Edad	Puntaje Días Alta	Puntaje Días Control	Puntaje Hospitalización
9400636.pdf	21.3059	4	4	9	2
94003227.pdf	22.3059	4	4	9	3
94005123.pdf	0	nan	nan	nan	nan
94005668.pdf	0	nan	nan	nan	nan
94006025.pdf	22.3059	4	4	9	3

ID	N Diagnosticos	Factor Ajuste	Suma Urgencia	Suma GES	Puntaje Promedio Ponderado
9400636.pdf	1	1.30103	3	0	2.30587
94003227.pdf	1	1.30103	3	0	2.30587
94005123.pdf	1	1.30103	3	0	2.30587
94005668.pdf	1	1.30103	3	0	2.30587
94006025.pdf	1	1.30103	3	0	2.30587

**Ilustración 6.2. Valores de puntajes de variables y Puntaje Prioridad**

## 6.2. Datos sintéticos

Considerando la disponibilidad de los médicos, la duración de la consulta post-alta y cantidad de box, el policlínico de Broncopulmonar tiene una capacidad máxima mensual de 196 bloques horarios, y el policlínico de Gastroenterología, de 288 bloques. En resumen, los médicos podrían atender a 424 pacientes al mes.

En relación con las orientaciones del Ministerio de Salud, al menos el 35% de las atenciones en especialidades deben reservarse para ser destinadas a primeras consultas (consultas nuevas). Es decir, que hasta el 65% debería ser ocupado para consultas repetidas, entre ellas los controles post-alta. En este escenario al menos 148 bloques horarios debían ser reservados para consultas nuevas y 276 bloques horarios para pacientes de consultas repetidas. Pero como en los escenarios de validación se llegaría a un +30% de demanda en pacientes, el total de episodios para el nuevo conjunto de datos fue de 358 episodios en total.

El contenido de este nuevo conjunto corresponde a 195 (~54%) Broncopulmonar y 163 (~45%) Gastroenterología, reproduciendo la presión asistencial original. La edad media es 62 años y la mediana de días de hospitalización es 11, virtualmente idéntica a la muestra original. El número de diagnósticos mantienen la moda en 1 y un máximo de 11, mientras que los códigos CIE-10 más frecuentes conservan su jerarquía. El tiempo a control promedia  $11 \pm 5$  días y, gracias al ruido  $\pm 5$  días, cubre el rango clínico observado (1-30 días). Todos los

valores se encontraron dentro de las proporciones y listo para su uso en el conjunto de pruebas de agendamiento.

### **6.3. Algoritmo de optimización - MILP**

El algoritmo MILP propuesto constituye la pieza central de la solución y materializa la hipótesis del apartado 4.1. Se compararon 3 versiones del modelo MILP: una configuración base con 4 hilos y límite de 900 segundos, y dos configuraciones paralelas más exigentes que utilizaron 2 procesos simultáneos, con 5 hilos cada uno y tiempos límite de 900 y 1500 segundos, respectivamente.

Los resultados obtenidos no mostraron mejoras significativas en los indicadores clave de desempeño entre las versiones. La cobertura, porcentaje de pacientes adelantados y retrasados, y el puntaje medio de prioridad se mantuvieron prácticamente constante en todos los escenarios evaluados. Solo se observaron ligeras variaciones marginales (menores a 0.4 días) en el promedio de días de agendamiento en las versiones paralelas. Por ejemplo, en los escenarios E10 y E11, la tercera versión (proceso simultaneo con 1500s) logró una reducción en el promedio de días de agendamiento ( $10.37 \rightarrow 9.99$  en E10 y de  $10.12 \rightarrow 9.97$  en E11), indicando una mejora menor en la agenda haciéndola solo un poco más eficiente temporalmente. Sin embargo, en E12 y E13 se presentó un aumento en el porcentaje de pacientes retrasados, sin mejoras compensatorias en el resto de los indicadores.

Estos resultados permitieron concluir que la primera versión (900s, 4 hilos) es suficiente para alcanzar soluciones de alta calidad, sin requerir mayor complejidad ni uso adicional de recursos computacionales. confirmando eficiencia y robustez de la configuración bajo las condiciones evaluadas. Por ello, esta fue adoptada como configuración final del modelo.

En las 13 instancias de prueba resolvió la agenda completa, entre 276 y 356 pacientes con una cobertura de 99.4% - 100% y sin exceder las 218 horas contractuales de las especialidades.

La estructura de la función objetivo que penaliza de forma diferenciada el retraso y la inequidad permitió recortar los extremos de espera (Delay p90/p95 de 216/270 a 180/234 bloques), mientras mantenía la desviación horaria entre médicos equilibrada y por debajo de las observadas en la simulación de la situación actual. Además, el modelo conservó una holgura intra-día de 4 y 10 bloques diarios, ofreciendo margen de flexibilidad operativa frente a contingencias. Cada escenario fue resuelto en un tiempo inferior a 90 minutos, lo que respalda la viabilidad del modelo para un uso rutinario diario.

En síntesis, el MILP genera agendas factibles que maximizan la atención de casos prioritarios, controlan los retrasos clínicamente relevantes y distribuye equitativamente la carga entre los recursos disponibles, cumpliendo de forma integral los objetivos general y específicos de esta tesis.

#### 6.4. Complejidad del modelo

Con el fin de dimensionar la carga computacional del modelo de optimización propuesto, se estimó el tamaño del problema en términos del número de variables y restricciones para un escenario representativo. En el escenario E2, que considera la asignación de 267 pacientes dados de alta, la formulación MILP genera un total de 1.286.417 variables, de las cuales 1.286.123 son binarias y 294 continuas. Las primeras son principalmente asociadas a la asignación de pacientes y doctores a bloques horarios, box y especialidades, mientras que las últimas corresponden al cálculo de retrasos, horas médicas totales y desviaciones individuales respecto al promedio. En escenarios con mayor carga de demanda, como E7 (+30%, 347 pacientes), el número total de variables se incrementa a 1.652.657, manteniéndose constante la estructura y lógica del modelo. Esta variación es proporcional al número de pacientes, lo que permite mantener una formulación estable.

El número de restricciones activas se estima entre 15.000 y 25.000, e incluye condiciones que aseguran la exclusividad de uso de bloques horarios, la compatibilidad entre pacientes y doctores, la unicidad de la asignación, el cumplimiento de horas máximas por especialidad, el cálculo de holgura intra-día y los criterios de priorización clínica definidos previamente. Adicionalmente, se integran restricciones específicas para penalizar retrasos, inequidad de carga médica, inasistencias o uso ineficiente de bloques horarios.

Dada la escala combinatoria, con cientos de miles de variables binarias y miles de restricciones interdependientes, el modelo se clasifica como un problema de alta complejidad computacional (NP-hard). Por lo tanto, se implementaron estrategias de resolución eficientes que incluyeron la aplicación de límites de tiempo, la ejecución mediante la cantidad máxima de hilos de procesamiento permitidos (*threads* = 4) y el uso del solver CBC (Branch and Cut), especializado en la resolución de problemas de programación lineal entera mixta de gran tamaño.

A pesar de su magnitud, todos los escenarios fueron resueltos exitosamente dentro de un rango de 15 a 71 minutos, gracias a la eficiencia del solver y a la formulación compacta del modelo. Estos resultados confirman la factibilidad computacional de la propuesta, así como su aplicabilidad en contextos operativos clínicos reales, manteniendo la precisión de los resultados y su adaptabilidad frente a variaciones de demanda o disponibilidad de recursos.

### 6.5. Validación – MILP

Las siguientes tablas muestran los valores obtenidos de las métricas de validación en cada uno de los escenarios.

Tabla 6.1. Métricas clave de validación MILP

Escenario	Coertura (%)	Episodios $\geq p90$ (n)	Retraso medio (bloques)	Horas médicas utilizadas (h) (% de 218)	Bloques utilizados (n) (% de 276)	Bloques ociosos	Holgura intra-día (bloques/día)	Puntaje medio diario
E1	100	50	28	138 (63%)	276 (100%)	160	8	3 ± 1.3

<b>E2</b>	100	50	38	138 (63%)	276 (100%)	160	8	3.16 ± 0.68
<b>E3</b>	100	29	26	145 (67%)	290 (105%)	146	7.3	3.58 ± 0.73
<b>E4</b>	100	31	31	152 (70%)	304 (110%)	132	6.6	3.46 ± 0.74
<b>E5</b>	100	32	24	158.5 (73%)	317 (115%)	119	6	3.39 ± 0.5
<b>E6</b>	100	34	24	165.5 (76%)	331 (120%)	105	5.2	3.36 ± 0.82
<b>E7</b>	99.4	37	29	178 (82%)	356 (130%)	80	4	3.2 ± 0.58
<b>E8</b>	100	27	28	131 (60%)	262 (95%)	174	8.7	3.7 ± 0.79
<b>E9</b>	100	25	21	124 (57%)	248 (90%)	188	9.4	3.81 ± 0.46
<b>E10</b>	100	24	23	117.5 (54%)	235 (85%)	201	10.1	3.87 ± 0.9
<b>E11</b>	100	29	25	138 (63%)	276 (100%)	160	8	3.73 ± 0.85
<b>E12</b>	100	29	22	138 (63%)	276 (100%)	160	8	3.78 ± 0.7
<b>E13</b>	100	29	18	138 (63%)	276 (100%)	160	8	3.71 ± 0.73
<b>E14</b>	100	29	20	138 (63%)	276 (100%)	160	8	3.7 ± 0.87

**Fuente:** Elaboración propia. Cálculos directos a partir de los archivos de resultados de agendas generados; un bloque = 30 min, capacidad contractual total = 218 h.

**Tabla 6.2. KPI complementarios – MILP**

Escenario	Delay p90 (bloques)	Delay p95 (bloques)	Adelantados / Retrasados		Desviación horas doctor (h)
			(n)	(% respecto a su cohorte)	
<b>E1</b>	216	270	123 / 144	44.6 / 52.2	13.2
<b>E2</b>	216	252	106 / 164	38.4 / 59.4	11.8
<b>E3</b>	198	252	110 / 164	37.9 / 56 .6	12.5

<b>E4</b>	198	252	123 / 171	40.5 / 56.2	13.4
<b>E5</b>	198	252	140 / 165	44.2 / 52.1	13.2
<b>E6</b>	198	270	138 / 182	41.7 / 55	13.4
<b>E7</b>	198	234	135 / 208	37.9 / 58.4	14.2
<b>E8</b>	216	270	103 / 148	39.3 / 56.5	13
<b>E9</b>	198	252	96 / 145	38.7 / 58.5	11.7
<b>E10</b>	198	252	93 / 133	39.6 / 56.6	11.8
<b>E11</b>	189	252	114 / 150	41.3 / 54.3	11.5
<b>E12</b>	216	252	117 / 148	42.4 / 53.6	11.2
<b>E13</b>	180	238	124 / 146	44.9 / 52.9	11.4
<b>E14</b>	198	252	127 / 142	46 / 51.4	11.2

**Fuente:** Elaboración propia. Cálculos directos a partir de los archivos de resultados de agendas generados; un bloque = 30 min, capacidad contractual total = 218 h.

**Tabla 6.3. Tiempos de ejecución de los escenarios - MILP**

Escenario	Tiempo de ejecución modelo (min)	Tiempo de ejecución escenario (min)
<b>E2</b>	26	55
<b>E3</b>	27	57
<b>E4</b>	34	59
<b>E5</b>	46	66
<b>E6</b>	37	66
<b>E7</b>	29	57
<b>E8</b>	15	38
<b>E9</b>	37	52
<b>E10</b>	28	59
<b>E11</b>	31	65
<b>E12</b>	29	52
<b>E13</b>	50	58
<b>E14</b>	27	71

**Fuente:** Elaboración propia. Cálculos directos a partir de los archivos de resultados de agendas generados.

Del análisis de estos 14 escenarios se extraen cuatro conclusiones principales:

- **Cobertura completa en escenarios.**

El modelo conserva una cobertura prácticamente total en todo el rango de prueba (99.4% - 100%). Incluso con +30% de demanda (E7), sólo 2 pacientes de baja prioridad quedan sin cita (0.6%), demostrando robustez frente a sobrecarga.

- **Flexibilidad con menor oferta.**

En los escenarios con restricción de bloques horarios (E11→E14) la cobertura se mantiene al 100%. El algoritmo reordena citas y preserva la prioridad clínica sin exceder las 138 h contractuales. Siendo algo que el proceso manual no garantiza.

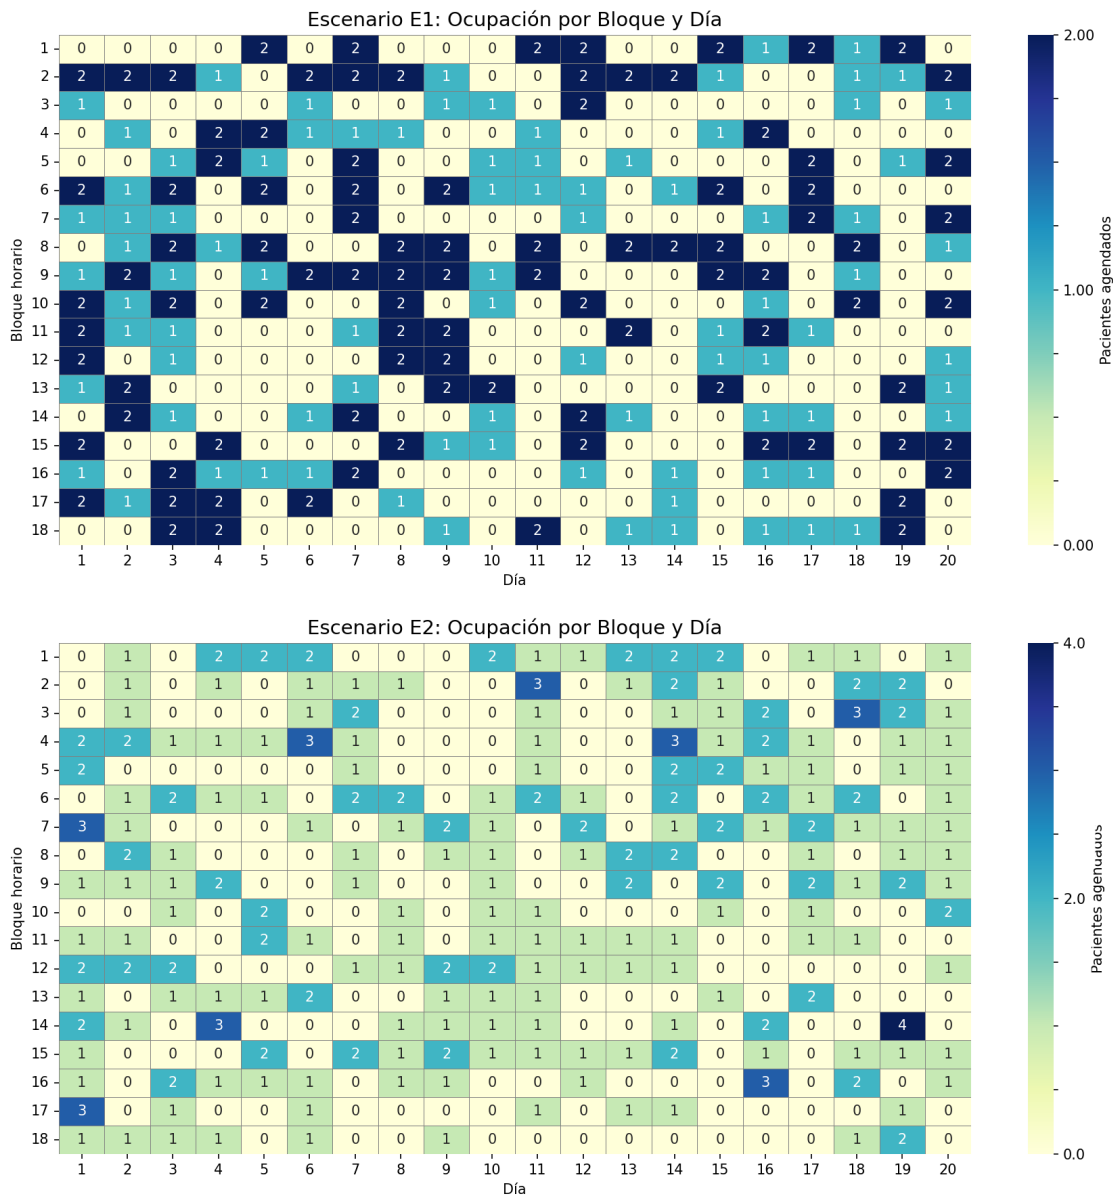
- **Mejora de calidad de la agenda.**

- I. Carga médica equilibrada: la desviación de estándar de horas asignadas se mantiene acotada, con un mínimo de 11.2 h (E12→E14) y máximo de 14.2 h (E7), demostrando que el modelo distribuye la carga asistencial de manera homogénea incluso bajo sobredemanda.
- II. Puntualidad controlada: el p90 del retraso baja de 216 bloques (E1) a 198 bloques en demanda alta y hasta 180 bloques con menor capacidad (E13), mientras el p95 cae de 270 a 234 bloques, acortando los extremos de los episodios más atrasados.

III. Menos ociosidad y holgura óptima: los bloques horarios vacíos se reducen de 160 a 80 (E7); la holgura intra-día oscila entre 4 y 10.1 bloques/días, evitando jornadas vacías o muy compactas.

- **Comportamiento adaptativo**

Con sobredemanda el porcentaje de adelantos tiende a bajar, ya que el modelo retrasa a pacientes menos prioritarios para proteger a los críticos. Con sub-demanda los adelantos rondan el 39-40%, el algoritmo adelanta más pero no suficiente para superar la mitad del total. En escenarios de capacidad recortada el porcentaje de adelantos vuelve a subir ligeramente entre 41-46% ya que el modelo comprime la agenda y ubica antes a los casos menos críticos para aprovechar los bloques horarios disponibles. Además, recorta el retraso medio a 21-23 bloques, manteniendo holgura mínima y sin aumentar el percentil 95 respecto al proceso actual.



**Ilustración 6.3. Comparación visual ocupación horaria por bloque y día - E1 vs E2**

Este comportamiento puede observarse de forma gráfica en la Ilustración 6.3, donde se compara la ocupación horaria del escenario E1

y el modelo MILP base. Se aprecia una distribución más compacta con menor holgura y utilización más uniforme de los bloques horarios. En el Anexo C pueden verse las demás ocupaciones por escenario.

La medición consideró dos tiempos: el tiempo de ejecución del modelo MILP, correspondiente únicamente al proceso de optimización, y el tiempo total del escenario, que incluye carga de datos, resolución del modelo y exportación de resultados. Los tiempos del modelo oscilaron entre 15 y 50 minutos, dependiendo de la complejidad del escenario. Por su parte, los tiempos totales fueron mayores, con un rango entre 38 y 71 minutos, debido al procesamiento adicional requerido para generar archivos de salida y calcular indicadores. Esta diferencia refleja la carga computacional asociada al manejo de datos más que al modelo en sí. Aun así, ningún escenario superó los 90 minutos, lo que demuestra que el sistema es eficiente y viable para su uso operativo en contextos clínicos reales.

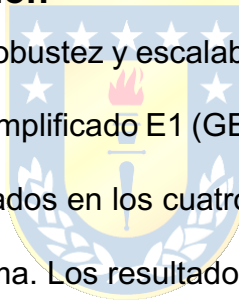
En conjunto, las métricas de validación demuestran que el modelo no solo mantiene la misma cobertura que el sistema actual, sino que además optimiza la distribución de la carga asistencial y reduce la ineficiencia operativa. Los KPI complementarios explican el mecanismo con el que lo consigue: (i) redujo los casos rezagados (Delay p90/p95 bajando hasta 180-234 bloques), (ii) administró el calendario con flexibilidad (adelantó pacientes cuando hubo holgura y aceptó retrasos controlados para proteger la prioridad clínica) y (iii) mantuvo la equidad

laboral, dejando la desviación de horas por médico dentro de un rango estrecho de 11.2 a 14.2 h.

Estos indicadores avalan que el algoritmo prioriza adecuadamente, controla los retrasos clínicamente relevantes y mantiene la equidad laboral, sin necesidad de modificar las reglas operativas de los policlínicos. A partir de esta visión global, el informe profundiza en los cuatro grupos de escenarios, comparando cada caso con la línea base E1 para ilustrar cómo el modelo se adapta a la variación de demanda y capacidad.

#### **6.5.1 Grupos de validación**

Con el fin de evaluar la robustez y escalabilidad del modelo MILP, se comparó el escenario del sistema simplificado E1 (GES + FIFO) con los 13 escenarios restantes (E2 → E14), organizados en los cuatro grupos de evaluación según el tipo de estrés aplicado al sistema. Los resultados fueron los siguientes:



### A. Análisis Grupo 1: E1 vs E2 – Mismo escenario, con y sin MILP

Tabla 6.4. Grupo 1: métricas clave

Métrica	E1	E2	Interpretación breve
Cobertura (%)	100	100	Acceso total conservado.
Episodios $\geq p90$ (n)	50	50	No hay variación.
Retraso Medio (bloques)	28	38	+10 bloques para equilibrar la carga.
Horas médicas utilizadas (h) (% de 218)	138 (63%)	138 (63%)	Misma carga contractual.
Bloques utilizados (bloques) (% de 276)	276 (100%)	276 (100%)	Capacidad física respetada.
Bloques ociosos	160	160	Ociosidad global inalterada.
Holgura intra-día (bloques/día)	8	8	No hay variación.
Puntaje medio diario	$3 \pm 1.3$	$3.16 \pm 0.68$	Menor oscilación.

Fuente: En base a Tabla 6.1

Tabla 6.5. Grupo 1: KPI complementarios

Métrica	E1	E2	Interpretación breve
Delay p90 (bloques)	216	216	Se mantiene.
Delay p95 (bloques)	270	252	El 5% más atrasado mejora 18 bloques (1 día)
Adelantos / Retrasos	(n)	123 / 144	Se desplaza agenda para aplanar peaks iniciales.
	(%)	44.6 / 52.2	
Desviación horas doctor (h)	13.2	11.8	carga más equitativa.

Fuente: En base a Tabla 6.2

En E2 el modelo MILP mantiene la cobertura total, todos los pacientes reciben cita al igual que en E1. Sin embargo, la manera en que se logra difiere del

primer escenario. La espera media pasa de 28 a 38 bloques, pero el extremo de la cola de rezagados mejora, el Delay p95 se acorta de 270 a 252 bloques (18 bloques). El algoritmo alarga ligeramente la espera de los casos menos urgentes para que ningún paciente quede excesivamente rezagado, permitiendo evitar el cuello de botella en el primer tramo de la agenda y agendando bloques horarios en el horizonte sin comprometer la ventana clínica de nadie. Se observó que, con esto, el puntaje medio diario apenas varía ( $3 \pm 1.3$  a  $3.16 \pm 0.68$ ) pero la desviación cae casi a la mitad, eliminando los peaks iniciales de carga.

Paralelamente, la desviación horaria por médico disminuyó de 13.2 a 11.8 h haciendo más parejo el reparto de trabajo. Si bien la holgura intra-día se mantiene en 8 bloques/día, el sistema la repartió más eficientemente entre los médicos y como resultado, el promedio de bloques horarios libres por especialista disminuyó de 1.65 a 1.26, logrando así agendas más compactas.

El número de citas adelantadas bajaron de 123 a 106 (-17) mientras que las retrasadas aumentaron de 144 a 164 (+20); el calendario se desplazó lo justo para suavizar la demanda de los primeros días para agendar a todos los casos sin prolongar demasiado su espera. Esto justifica el aumento del retraso medio y la reducción de los casos en p95.

En conjunto, con la misma demanda y sin necesidad de recursos adicionales, el escenario E2 logra evitar el cuello de botella, balancear la variabilidad

del flujo de pacientes y optimizar la eficiencia de la agenda, entregando una más equilibrada y eficiente.



### B. Análisis Grupo 2: E1 vs E3 → E7 - demanda creciente

Tabla 6.6. Grupo 2: métricas clave

Métrica	E1	E3	E4	E5	E6	E7	Interpretación breve
Cobertura (%)	100	100	100	100	100	99.4	Cobertura total hasta E6; 2 pacientes quedan fuera en E7.
Episodios $\geq$ p90 (n)	50	29	31	32	34	37	Aumentan los casos prioritarios citados a medida que crece la demanda.
Retraso medio (bloques)	28	26	31	24	24	29	Retraso controlado $\leq$ 31 bloques a pesar del aumento de demanda.
Horas médicas utilizadas (h)(% de 218)	138 (63%)	145 (67%)	152 (70%)	158.5 (73%)	165.5 (76%)	178 (82%)	El uso de capacidad crece linealmente.
Bloques utilizados (%)	276 (100%)	290 (105%)	304 (110%)	317 (115%)	331 (120%)	356 (130%)	Supera la norma del 65% para proteger el acceso a atenciones.
Bloques ociosos	160	146	132	119	105	80	La ociosidad global desciende.
Holgura intra-día (bloques)	8	7.3	6.6	6	5.2	4	Jornadas más compactas.
Puntaje medio diario	$3 \pm 1.3$	$3.58 \pm 0.73$	$3.46 \pm 0.74$	$3.39 \pm 0.5$	$3.36 \pm 0.82$	$3.2 \pm 0.58$	Complejidad creciente sin peaks abruptos.

Fuente: En base a Tabla 6.1.

Tabla 6.7. Grupo 2: KPI complementarios

Métrica	E1	E3	E4	E5	E6	E7	Interpretación breve	
Delay p90 (bloques)	216	198	198	198	198	198	A mayor demanda más se acota el retraso de los más rezagados.	
Delay p95 (bloques)	270	252	252	252	270	234	El 5% más retrasado mejora.	
Adelantos / Retrasos	(n)	123 / 144	110 / 164	123 / 171	140 / 165	138 / 182	135 / 208	Se aceptan más retrasos para los bloques horarios vacíos y protección de las prioridades.
	(%)	44.6 / 52.2	37.9 / 56.6	40.5 / 56.2	44.2 / 52.1	41.7 / 55	37.9 / 58.4	
Desviación horas doctor (h)	13.2	12.5	13.4	13.2	13.4	14.2	MILP reparte mejor la sobrecarga creciente.	

**Fuente:** *En base a Tabla 6.2.*

A medida que la demanda aumentó, el modelo mantuvo la cobertura de citas en un 100% hasta el escenario E6. Solo en el escenario más exigente (E7) un marginal 0.6% de pacientes de baja prioridad (2 en total) quedó sin cita, lo que resultó en una cobertura del 99.4%. Este comportamiento confirmó que el algoritmo priorizó consistentemente los casos más críticos, incrementando los episodios prioritarios atendidos.

A pesar del aumento de la demanda, el sistema demostró una gestión eficiente del tiempo y la capacidad. El retraso medio osciló entre 24 y 31 bloques horarios (aproximadamente 12 a 15 horas), y los retrasos extremos se acortaron significativamente: el percentil 90 del retraso se redujo de 216 a 198 bloques, y el percentil 95 disminuyó a 234 incluso en el escenario más demandante. La holgura intra-día disminuyó gradualmente de 7.3 a 4 bloques por día; a pesar de esta reducción, se mantuvo un pequeño margen para contingencias.

La distribución de la carga laboral entre los especialistas se mantuvo controlada, asegurando que ningún especialista superara las 218 horas mensuales ni quedara subutilizado. El puntaje medio diario subió levemente a 3.58 en los incrementos iniciales de demanda y volvió a 3.2 en el escenario E7. Esta fluctuación indicó que el modelo ajustó la asignación de pacientes, acomodando a aquellos con menor prioridad cuando la ocupación global superaba el 120%.

A pesar de estos resultados, el modelo superó el umbral del 65% de bloques horarios utilizados, haciendo parecer un incumplimiento de la práctica operativa habitual. Sin embargo, esta sobreocupación se justifica por las siguientes razones. En primer lugar, se incluye una holgura intra-día que reemplaza al margen utilizado en la planificación manual. Adicionalmente, se respeta estrictamente el máximo de horas médicas contractuales, sin sobrepasar la disponibilidad de recurso humano. Asimismo, la sobreutilización de bloques horarios permite responder de forma adaptativa al aumento de demanda, especialmente en escenarios como E7, donde limitar la capacidad habría implicado dejar pacientes críticos sin atención. Finalmente, el modelo evita solapamientos y mantiene una asignación operativamente viable, garantizando eficiencia sin comprometer la calidad asistencial. Por lo tanto, el uso extendido de bloques horarios debe interpretarse como una decisión óptima bajo condiciones de presión asistencial, y no como una falla del diseño.

En síntesis, el modelo respondió positivamente al estrés de una demanda creciente: compactó la agenda, redujo los retrasos extremos y mantuvo un equilibrio en la carga laboral. La cobertura solo se vio mínimamente afectada (una caída marginal del 0.6%) cuando la ocupación global rebasó el 125% (E7). Este punto se identificó como un umbral operativo crítico, a partir del cual sería conveniente considerar un aumento de recursos o la reprogramación de especialidades. Los dos pacientes que no obtuvieron cita en el escenario E7 quedan fuera porque los bloques horarios libres restantes correspondían a otra especialidad,

estaban fuera de su ventana clínica o su asignación habría provocado que un médico excediera su límite horario. La función objetivo del modelo penalizaba más severamente estas violaciones que dejar sin cita a pacientes de baja prioridad.



### C. Análisis Grupo 3: E1 vs E8 → E10 - demanda decreciente

Tabla 6.8. Grupo 3: métricas clave

Métrica	E1	E8	E9	E10	Interpretación breve
Cobertura (%)	100	100	100	100	Acceso intacto pese a menor demanda.
Episodios $\geq p90$ (n)	50	27	25	24	Disminución proporcional a la demanda.
Retraso medio (bloques)	28	28	21	23	Las citas se adelantan levemente.
Horas médicas utilizadas (h) (% de 218h)	138 (63%)	131 (60%)	124 (57%)	117.5 (54%)	20 h liberadas respecto a E1.
Bloques utilizados (% de 276)	276 (100%)	262 (95%)	248 (90%)	235 (85%)	Se cumple con la norma del 65%
Bloques ociosos	160	174	188	201	Crece la ociosidad.
Holgura intra-día (bloques/día)	8	8.7	9.4	10.1	Más bloques horarios vacíos, jornadas relajadas.
Puntaje medio diario	3 ± 1.3	3.7 ± 0.79	3.81 ± 0.46	3.87 ± 0.9	Carga baja y estable.

Fuente: En base a Tabla 6.1

Tabla 6.9. Grupo 3: KPI complementarios

Métrica	E1	E8	E9	E10	Interpretación breve	
Delay p90 (bloques)	216	216	198	198	Los retrasos de los más rezagados primero se alargan, pero mejora al caer 10-20%.	
Delay p95 (bloques)	270	270	252	252	El 5% más atrasado baja 18 bloques cuando la demanda cae $\geq 10\%$ .	
Adelantos / Retrasos	(n)	123 / 144	103 / 148	96 / 145	93 / 133	Con menos carga el algoritmo adelanta algunos pacientes.
	(%)	44.6 / 52.2	39.3 / 56.5	38.7 / 58.5	39.6 / 56.6	

<b>Desviación doctor (h)</b>	<b>horas</b>	13.2	13	11.7	11.8	La variabilidad baja.
----------------------------------	--------------	------	----	------	------	-----------------------

Fuente: En base a Tabla 6.2

Al disminuir la demanda, el modelo mantiene la cobertura total y cumple la política de prioridad sin necesidad de sobreexplotar recursos. En lo que respecta a la cobertura y prioridad, todos los pacientes recibieron cita, y el percentil dinámico de citación continuó capturando el 10% más crítico. Esto se evidenció en la disminución de los episodios prioritarios atendidos de 27 a 24, lo que se ajustó proporcionalmente a la reducción de la demanda.

Respecto a los adelantos y retrasos, estos se mantienen estables. Con una disminución del 5% en la demanda (E8), la espera media se mantuvo en 28 bloques horarios. Con recortes del 10% y 15% en la demanda, la espera cayó a 21 y 23 bloques horarios respectivamente. Los extremos reflejaron una tendencia similar: el Delay p90 se redujo 216 a 198 bloques, y el p95 disminuyó de 270 a 252 bloques. Estos resultados demostraron que el algoritmo de adelanto controló eficazmente los huecos cercanos a la fecha solicitada.

El uso de recursos también se optimizó. Las horas médicas efectivas descendieron gradualmente de 138 a 117.5 horas, lo que liberó aproximadamente 20 horas (equivalente a un día de consulta) sin superar los topes contractuales de los profesionales. En consecuencia, la ocupación de bloques disminuyó al

85%, y la ociosidad aumentó a 201 bloques. Esta ociosidad adicional, que representó y la holgura operativa entre 8.7 y 10.1 bloques diarios (equivalente a 4-5 horas en los policlínicos), se distribuyó eficazmente, y dejó un margen suficiente para absorber contingencias sin necesidad de prolongar la jornada laboral de los médicos.

Respecto a la equidad laboral, la desviación horaria por médico se estabilizó en un rango de 13 a 11.7 horas. Confirmando que el modelo redistribuyó la carga de trabajo de manera efectiva, incluso en escenarios con menor demanda augurando que ningún especialista quedara subutilizado o con una carga desequilibrada.

Finalmente, el modelo generó adelantos de citas que oscilaron entre 103 y 93 pacientes. Aunque estas cifras fueron menores que los 123 pacientes adelantados en E1, resultaron significativas para confirmar la adaptabilidad del sistema para seguir ofreciendo citas anticipadas bajo menor presión. Paralelamente, los retrasos disminuyeron de 148 a 133, lo que representó una mejora frente a los 144 retrasos de E1, traduciéndose en un calendario de citas hacia fechas más convenientes respecto a accesibilidad.

En resumen, el modelo logró liberar horas y bloques horarios en contexto de demanda reducida sin comprometer cobertura ni prioridad, optimizando adelantos y acotando los extremos de espera. De igual forma presentó un equilibrio más eficiente de la carga médica y, si bien este beneficio implicó un aumento

planificado de la holgura y bloques horarios vacíos, se tradujo en una mejora de la eficiencia global del sistema, fortaleciendo la adaptabilidad ante fluctuaciones de demanda.



#### D. Análisis Grupo 4: E1 vs E11 → E14 - recorte de capacidad

Tabla 6.10. Grupo 4: métricas clave

Métrica	E1	E11	E12	E13	E14	Interpretación breve
Cobertura (%)	100	100	100	100	100	Acceso se mantiene a pesar del recorte.
Episodios $\geq$ p90 (n)	50	29	29	29	29	El 10% prioritario se sigue agendando.
Retraso medio (bloques)	28	25	22	18	20	Retraso controlado.
Horas médicas utilizadas (h)(% de 218h)	138 (63%)	138 (63%)	138 (63%)	138 (63%)	138 (63%)	Se utiliza al máximo sin pasar de las 218 h.
Bloques utilizados (% de 276)	276 (100%)	276 (100%)	276 (100%)	276 (100%)	276 (100%)	Se mantiene constante.
Bloques ociosos	160	160	160	160	160	Ociosidad global inalterada; se redistribuye, sin incrementar.
Holgura intradía (bloques/día)	8	8	8	8	8	Las jornadas conservan los espacios libres.
Puntaje medio diario	$3 \pm 1.3$	$3.73 \pm 0.85$	$3.78 \pm 0.7$	$3.71 \pm 0.73$	$3.7 \pm 0.87$	La carga se intensifica y es uniforme.

Fuente: En base a Tabla 6.1

Tabla 6.11. Grupo 4: KPI complementarios

Métrica	E1	E11	E12	E13	E14	Interpretación breve
Delay p90 (bloques)	216	189	216	180	198	Se mantiene.
Delay p95 (bloques)	270	252	252	238	252	El 5% del extremo se mantiene 18 bloques por debajo del proceso actual. Y 32 bloques en E13.
Adelantos / Retrasos	(n)	123 / 144	114 / 150	117 / 148	124 / 146	MILP adelantó menos y retrasó más comparado con el proceso actual.
	(%)	44.6 / 52.2	41.3 / 54.3	42.4 / 53.6	44.9 / 52.9	
Desviación horas doctor (h)	13.2	11.5	11.2	11.4	11.2	El reparto se mantiene equilibrado a pesar del ajuste.

**Fuente:** En base a Tabla 6.2.

Al reducirse la capacidad disponible de manera progresiva de los escenarios E11 a E14, el modelo demostró su capacidad para reorganizar la agenda sin sacrificar desempeño. En términos de cobertura y prioridad, a pesar de disponer de menos bloques horarios por especialidad, la cobertura se mantuvo en 100% en cada escenario. Esto aseguró que los episodios más prioritarios, siempre recibieran cita confirmando la resiliencia del sistema ante restricción de recursos.

En este escenario era esperable ver una caída en adelantos y un aumento en retrasos, sin embargo, los datos muestran que los adelantos se mantienen e incluso superan los niveles de E1 en E13 y E14 (44.9% y 46% versus 44.6% en E1), demostrando la eficiencia para encontrar y ocupar bloques horarios vacíos en la agenda, incluso con menos bloques disponibles. Los retrasos, aunque aumentan ligeramente al inicio, logran descender y terminar incluso por debajo de E1 en E14. Los extremos reflejaron esta tendencia favorable: el Delay p90 descendió a 189 bloques, y el p95 se mantuvo en 252 bloques. Estos resultados demuestran que el sistema fue capaz de evitar la acumulación de esperas prolongadas a pesar de una oferta de capacidad más limitada.

En lo que concierne a los recursos, las horas asignadas permanecieron estables en 138 horas (63% de la dotación contractual), y los 276 bloques post-alta se siguieron utilizando al 100%. Además, la ociosidad global (160 bloque) no

aumentó, lo que evidenció una eficaz redistribución interna de los recursos disponibles. A pesar de estas restricciones, la holgura operativa se mantuvo estable, conservando un colchón de 8 bloques por día (~4 horas en total); margen suficiente para absorber contingencias, permitiendo mantener jornadas compactas sin la necesidad de generar horas extras.

La equidad laboral se vio notablemente reforzada. La desviación de horas por médico se redujo, pasando de 13.2 horas (E1) a 11.5 horas (E11) y posteriormente 11.2 horas (E12 → E14). Esta mejora de ~15% demostró que la carga de trabajo entre los especialistas se equilibró de forma efectiva, incluso con la restricción de bloques horarios.

Finalmente, el calendario se desplazó con prudencia. Los adelantos de citas se mantuvieron en un rango controlado, oscilando entre 114 y 127 pacientes (123 en E1), y los retrasos solo subieron moderadamente, pasando de 150 a 142 (144 en E1). Este comportamiento indicó la capacidad del algoritmo para priorizar el movimiento de citas de menor prioridad hacia el final de la ventana clínica, dejando espacio en el calendario para los casos críticos sin generar demoras excesivas.

Recapitulando, el modelo demostró la capacidad para absorber recortes de capacidad de hasta el 20% sin sacrificar la cobertura ni la prioridad de las atenciones. Esto se logró al adelantar selectivamente a los pacientes de menor urgencia, mantener una holgura mínima constante, acortar los retrasos de los

casos más problemáticos y homogeneizar la carga entre médicos. Todos se consiguieron sin superar las restricciones contractuales, lo que valida la robustez y eficiencia del modelo en escenarios de recursos limitados.



### ***E. Resumen comparativo***

- **Grupo 1- Mismo escenario, con y sin MILP:**

- Cobertura se mantiene en 100%.
- Aumenta el retraso medio de 28 a 38 bloques, pero mejora el retraso extremo (Delay p95) de 270 a 252 bloques (reducción de 18 bloques, ~9 h), reduciendo la espera de los más rezagados.
- La desviación horaria entre médicos mejora de 13.2 a 11.8 horas, indicando carga más equitativa.
- La holgura intra-día permanece constante 8 bloques/día, pero en E2 se permite repartir los bloques en más jornadas pudiendo eliminar el embudo inicial sin añadir recursos.
- El puntaje medio diario se estabiliza ( $3 \pm 1.3$  a  $3.16 \pm 0.68$ ), mostrando menor variabilidad diaria.

- **Grupo 2 - demanda creciente:**

- Cobertura total hasta E6. En E7 (demanda +30%), la cobertura disminuye marginalmente a 99.4% (se pierden 2 pacientes).
- El retraso medio se mantiene estable, oscila entre 24 y 31 bloques, y los retrasos extremos (Delay p90/p95) mejoran a 162/216 bloques respectivamente en E7, desde 216/270 en E1.
- La ocupación sube hasta 130% de la capacidad (356 bloques), mientras que la holgura intra-día se reduce ligeramente de 8 a 4 bloques/día, manteniendo capacidad de contingencias.

- La desviación de horas médicas se mantiene controlada, con un máximo de 14.2 h en E7, demostrando efectiva redistribución de trabajo médico.
  - El modelo prioriza adecuadamente los casos críticos, compacta la agenda y reparte la carga sin exceder los límites contractuales.
- **Grupo 3 - demanda decreciente:**
    - Cobertura se mantiene en 100%.
    - El retraso medio mejora de 28 bloques (E1) a un rango entre 21 y 23 bloques. Los retrasos extremos mejoran, con Delay p90/p95 bajando a 198/252 bloques en E10, comparados con 216/270 en E1.
    - Se liberan hasta 20 horas médicas, con ocupación de bloques bajando al 85% (235 bloques), aumentando la holgura intra-día hasta 10 bloques/día.
    - La ociosidad sube hasta 201 bloques debido a la menor demanda, aunque sin afectar la eficiencia global.
    - La desviación horaria entre médicos se reduce favorablemente a 11.7-11.8 horas, mostrando una redistribución eficiente de la carga laboral.
- **Grupo 4 - capacidad reducida:**
    - Cobertura se mantiene en 100% en todos los escenarios pese a los recortes.
    - El retraso medio mejora disminuyendo desde 28 bloques en E1 hasta un rango entre 18 y 25 bloques.

- Los retrasos extremos (Delay p90/p95) también mejoran, con p90 manteniéndose entre 180 y 216 bloques y p95 consistentemente en 252 bloques (18 bloques menos que en E1).
- El puntaje medio diario sube de  $3 \pm 1.3$  en E1 a aproximadamente 3.7 en E11-E14, indicando una compacta y uniformemente crítica.
- La holgura intra-día se mantiene constante en 8 bloques/día, y no varía la ociosidad.
- La desviación horaria entre médicos mejora estabilizándose en 11.2 – 11.5 horas, lo que refleja equidad laboral sostenida.



## **Capítulo 7. CONCLUSIONES Y TRABAJO FUTURO**

---

La presente tesis de magíster abordó el desafío de optimizar el agendamiento de citas médicas post-alta en policlínicos de alta demanda, un proceso tradicionalmente manual y carente de priorización clínica. Se diseñó, desarrolló y validó una solución tecnológica que integra un Sistema Basado en Reglas (SRB) para la estratificación de pacientes con un modelo de Programación Lineal Entera Mixta (MILP) para la asignación de citas, demostrando que es posible automatizar el proceso de manera eficiente, equitativa contrada en la urgencia del paciente.



En línea con el primer objetivo específico, se recopiló y estructuró la información de 266 episodios de egreso del Servicio de Medicina Interna, complementada con datos operativos sobre la disponibilidad de médicos, box y horarios (Tabla 5.2-Tabla 5.5). La muestra inicial resultó insuficiente para una validación robusta, lo que motivó la generación de un conjunto sintético de 358 episodios. Este nuevo conjunto, dimensionado para someter el sistema a un escenario de estrés (+30% de demanda), reprodujo las distribuciones estadísticas de la cohorte original, asegurando la representatividad clínica y operativa necesaria para evaluar el modelo.

El segundo objetivo se cumplió mediante el diseño de un SBR que asigna un puntaje de prioridad a cada paciente (Tabla 5.6-Tabla 5.7). Este sistema formalizó el conocimiento experto y los criterios clínicos en un conjunto de reglas de producción, heurísticas y de control, ponderando variables como la gravedad de diagnóstico (CIE-10), la etapa GES, la edad, los días de hospitalización y el retraso respecto a la fecha de control indicada. La implementación de un factor de ajuste logarítmico (5.1) para pacientes con múltiples diagnósticos constituyó una innovación metodológica que evitó sesgos, garantizando una priorización equilibrada y justa. Este puntaje se convirtió en el eje de la función objetivo del optimizador, traduciendo la necesidad clínica a un valor cuantificable.

La formulación del modelo MILP, correspondiente al tercer objetivo, materializó la hipótesis central del estudio. El modelo maximiza la suma de los puntajes de prioridad de los pacientes agendados, al tiempo que minimiza las penalizaciones por retrasos, ociosidad de recursos y desigualdad en la carga horaria entre médicos. Su estructura matemática integró con éxito las múltiples restricciones del entorno real: capacidad de policlínicos, horarios contractuales de los especialistas, ventanas clínicas de atención y la reserva del 65% de los bloques para controles post-alta. La implementación se realizó en Python con la biblioteca PuLP, demostrando ser computacionalmente factible para una potencial aplicación diaria, con tiempos de resolución inferiores a 75 minutos en los escenarios más complejos (Tabla 6.3).

Finalmente, para el cuarto objetivo, se evaluó el desempeño del sistema en 14 escenarios simulados que testearon su comportamiento ante variaciones de demanda (de -15% a +30%) y recortes de capacidad (de -5% a -20%) (Tabla 5.17, Tabla 5.18). Los resultados (Tabla 6.1-Tabla 6.3) validaron la robustez y adaptabilidad del modelo. La cobertura de pacientes se mantuvo en un 100% en casi todos los escenarios, con una caída mínima a 99.4% solo bajo la máxima sobrecarga (+30% de demanda).

Métricas clave como el retraso medio se mantuvieron controladas (entre 18 y 38 bloques), y los casos más extremos (percentil 95 de retraso) mejoraron, reduciéndose de 270 a 234 bloques. La desviación de la carga horaria entre médicos se mantuvo acotada ( $\pm 4$  horas), demostrando la capacidad del modelo para distribuir el trabajo de forma equitativa. Además, el sistema redujo la ociosidad de bloques hasta en un 15%, optimizando el uso de infraestructura física, como se ilustra en los gráficos de ocupación horaria por bloque y día (Anexo 9.18-Anexo 9.29).

La contribución original de esta tesis radica en la creación de una solución integral e híbrida que cierra una brecha importante en la literatura y en la práctica hospitalaria chilena, específicamente en el agendamiento post-alta. A diferencia de otros estudios previos centrados en ámbitos teóricos o en contextos internacionales, este trabajo integra la extracción de variables desde la epicrisis, una priorización clínica formalizada mediante un SBR y una optimización matemática

con MILP, todo alineado con la realidad operativa y normativa de Chile. El modelo no solo asigna citas, si no que gestiona activamente la agenda para proteger a los pacientes críticos, equilibrar los recursos y generar KPIs que facilitan la toma de decisiones.

Entre las fortalezas del sistema destacan la robustez y flexibilidad. El algoritmo demostró ser capaz de absorber fluctuaciones significativas de oferta y demanda son comprometer la cobertura ni la equidad, atributo fundamental para la gestión de sistemas de salud dinámicos. Su capacidad para operar con los recursos existentes, sin requerir horas médicas o box adicionales, lo convierte en una propuesta de alto valor y factibilidad para centros de salud que enfrentan restricciones presupuestarias.



No obstante, el estudio presenta limitaciones. La validación se basó en un conjunto de datos sintético, y aunque fue diseñado con rigor, los resultados deben ser interpretados como una aproximación al comportamiento en un entorno real. El modelo asume que la disponibilidad de médicos y box es constante durante el horizonte de planificación, sin considerar ausencias imprevistas. Asimismo, la efectividad de la optimización depende directamente de la calidad del puntaje generado por el SBR, cuyo calibrado podría requerir ajustes.

En conclusión, esta investigación demuestra que la aplicación de técnicas de investigación de operaciones, como la programación lineal entera mixta,

ofrece soluciones potentes y realistas a problemas complejos de la gestión sanitaria. El sistema propuesto se establece como un modelo de referencia para la modernización del agendamiento de citas, capaz de disminuir tiempos de espera, optimizar el uso de recursos y liberar al personal clínico de tareas administrativas, impactando positivamente en la calidad y continuidad de la atención post-alta.


### 7.1. Trabajo Futuro

Si bien los resultados obtenidos son prometedores, constituyen un primer paso hacia una gestión de agendas completamente inteligente y dinámica. A partir de las conclusiones y las limitaciones identificadas, se proponen las siguientes líneas de investigación y desarrollo futuro:

- i. **Incorporación de estocasticidad:** el modelo actual es determinístico. Una mejora sería incorporar la incertidumbre inherente a los sistemas de salud, como la inasistencia de pacientes o la variabilidad en la duración de las consultas cuando se estudien más de un tipo de consultas. Se podría desarrollar un modelo de programación estocástica o utilizar técnicas de aprendizaje automático para predecir la probabilidad de inasistencia de cada paciente, basándose en su historial y características demográficas. Esta predicción podría integrarse en la función objetivo del MILP para generar políticas de sobreagendamiento inteligentes que minimicen la ociosidad sin aumentar excesivamente la congestión. Esto requeriría datos históricos detallados sobre la asistencia a citas.

- ii. **Ampliación a múltiples servicios y optimización Interpoliclínicos:** el estudio se limitó a dos policlínicos del Servicio de Medicina Interna. Un paso lógico es escalar el modelo para abarcar todos los policlínicos del servicio y, eventualmente, del hospital. Esto introduciría a una mayor complejidad de tener que gestionar los recursos compartidos (box) y la posibilidad de que un mismo paciente requiera controles en diferentes especialidades. Una optimización a nivel hospitalario permitiría balancear la carga de trabajo no solo entre médicos de la misma especialidad, si no entre diferentes servicios, identificando sinergias y reduciendo cuellos de botella globales.
- iii. **Evaluación económica y de impacto clínico:** sería de gran valor realizar una evaluación económica formal que cuantifique el ahorro de costos derivado de la optimización (reducción de horas extra, uso eficiente de la infraestructura) y el impacto clínico a largo plazo. Se podría medir si un agendamiento más oportuno para los pacientes críticos se correlaciona con una disminución en las tasas de readmisión hospitalaria o complicaciones. Este análisis requeriría una colaboración multidisciplinaria con economistas de la salud u equipos clínicos para seguir cohortes de pacientes y requeriría acceso a datos de costos y resultados clínicos.

- iv. **Desarrollo de una interfaz de usuario para gestión clínica:** Para facilitar su adopción, el paso final es traducir el algoritmo en una herramienta de software con una interfaz gráfica intuitiva. Este sistema debería permitir al personal administrativo y jefes de servicio visualizar las agendas propuestas, ejecutar simulaciones (si por ejemplo un médico se ausenta) y monitorear los KPIs en tiempo real a través de un tablero de control. Su desarrollo exigiría la colaboración con el futuro usuario para satisfacer las necesidades o conocer los parámetros útiles, ingenieros de software y diseñadores de experiencia de usuario para asegurar que la herramienta sea funcional, usable y se integre fluidamente con los sistemas de información hospitalarios existentes.



## Capítulo 8. GLOSARIO

---

- ABS : Simulación Basada en Agentes (Agent-Based Simulation).
- ACO : Algoritmo de Optimización de Colonias de Hormigas (Ant Colony Optimization).
- IA : Inteligencia Artificial (Artificial Inteligencia)
- API : Interfaz de Programación de Aplicaciones (Application Programming Interface)
- CIE : Clasificación Internacional de Enfermedades.
- CNN : Redes Neuronales Convolucionales (Convolutional Neural Networks).
- C++ : Lenguaje de programación C++.
- DEIS : Departamento de Estadísticas e Información de Salud.
- DES : Simulación de Eventos Discretos (Discrete Event Simulation).
- DRL : Aprendizaje Profundo por Refuerzo (Deep Reinforcement Learning).
- GA : Algoritmo Genético (Genetic Algorithm).
- GES : Garantías Explícitas en Salud. Es un sistema de gestión de pacientes con enfoque de riesgo.
- Google
- Workspace : Plataforma que alberga y ofrece herramientas de colaboración, como Gmail, Calendario, Meet, Chat, Drive, Documentos, Hojas de cálculo, Presentaciones, Formularios, Sites y muchas otras más.
- Gurobi : Solucionador de problemas de optimización matemática.
- IBM CPLEX : Solucionador de problemas de programación lineal y mixta de IBM.
- IFRH : Heurística Incremental de Ajuste y Liberación.
- IPPS : Programación de Procesos Integrados (Integrated Process Planning and Scheduling).

KPI	: Indicador Clave de Rendimiento (Key Performance Indicator).+
SI	: Sistemas de Información (Information System).
TI	: Tecnología de la Información (Information Technology).
MILP	: Programación Lineal Entera Mixta (Mixed Integer Linear Programming).
ML	: Aprendizaje Automático (Machine Learning).
MMCO	: Modelo de Colaboración de Optimización Multi-MILP (Multi-MILP Model Collaborative Optimization).
MSM	: Método de programación basado en cadenas de Markov (Markovian Scheduling Method).
OMS	: Organización Mundial de la Salud (World Health Organization (WHO)).
OLAS	: Overlapping Scheduling, método de programación que minimiza el tiempo de acceso.
PASP	: Problema de Programación de Admisión de Pacientes.
PSO	: Optimización de Enjambre de Partículas (Particle Swarm Optimization).
PSP	: Programación de Personal.
Python	: Lenguaje de programación Python.
RNN	: Redes Neuronales Recurrentes (Recurrent Neural Networks).
SBR	: Sistema Basado en Reglas.
TENS	: Técnico de nivel superior en Enfermería.
WOA	: Algoritmo de Optimización de Ballenas (Whale Optimization Algorithm).

## Capítulo 9. REFERENCIAS

---

[1] Superintendencia de Salud, “Glosario de términos de uso frecuente,” Gob.cl. [En línea]. Disponible en: [https://www.supersalud.gob.cl/664/articles-18119\\_recurso\\_1.pdf](https://www.supersalud.gob.cl/664/articles-18119_recurso_1.pdf). [Consultado: 30-nov-2023].

[2] J. P. Porto y A. Gardey, “Epicrisis,” Definición.de, 16-ago-2017. [En línea]. Disponible en: <https://definicion.de/epicrisis/>. [Consultado: 03-dic-2023].

[3] Superintendencia de Seguridad Social, “C. Alta inmediata, alta laboral y alta médica.” [En línea]. Disponible en: <https://www.suseso.cl/613/w3-propertyvalue-137069.html>. [Consultado: 03-dic-2023].

[4] Ministerio de Salud – Gobierno de Chile, “Minsal presenta Sistema de Gestión de Pacientes con Enfoque de Riesgo para apoyar priorización de las listas de espera.” [En línea]. Disponible en: <https://www.minsal.cl/minsal-presenta-sistema-de-gestion-de-pacientes-con-enfoque-de-riesgo-para-apoyar-priorizacion-de-las-listas-de-espera/>. [Consultado: 03-dic-2023].

[5] Clínicas de Chile, “Listas de espera se ordenarán según el riesgo del paciente y no por su fecha de ingreso,” 07-feb-2019. [En línea]. Disponible en: <https://www.clinicasdechile.cl/noticias/listas-de-espera-se-ordenaran-segun-el-riesgo-del-paciente-y-no-por-su-fecha-de-ingreso/>. [Consultado: 03-dic-2023].

[6] F. B. Valdés Brito, “Propuesta de automatización para proceso de agendamiento de citas médicas post-alta a partir de epicrisis en el servicio de medicina interna del Hospital Las Higueras.”, Concepción, 2024. [En línea]. Disponible: <https://repositorio.udec.cl/handle/11594/10266>.

[7] E. Nieto, “Tecnologías de la información,” Blog – Bootcamps, 05-abr-2023. [En línea]. Disponible en: <https://bootcampvirtual.udd.cl/blog/tecnologias-de-la-informacion/>. [Consultado: 21-sep-2023].

[8] J. Godoy Olave y J. Barraza Mesquida, “La ficha clínica mirada desde la legislación chilena actual,” Acta Bioeth., vol. 24, núm. 2, pp. 181–188, 2018.

- [9] G. M. Fuenzalida Del Valle, “Agendamiento dinámico de citas médicas a través de un proceso de decisión markoviano,” Magíster en Ciencias de la Ingeniería, Pontificia Universidad Católica de Chile, Santiago, Chile, 2016. doi: 10.7764/tesisUC/ING/16841.
- [10] D. Sarkar, “Chapter 1: Text analytics,” en *Text Analytics with Python: A Practitioner’s Guide to Natural Language Processing*, 2nd ed., Berkeley, CA, USA: Apress, 2019, pp. 66–67.
- [11] World Health Organization, “Estrategia mundial sobre salud digital 2020–2025,” 18-ago-2021. [En línea]. Disponible en: <https://www.who.int/es/publications/i/item/9789240020924>. [Consultado: 06-oct-2023].
- [12] Ministerio de Salud – Gobierno de Chile, “Estrategia Nacional de Salud para los Objetivos Sanitarios al 2030,” feb-2022. [En línea]. Disponible en: <https://www.minsal.cl/wp-content/uploads/2022/03/Estrategia-Nacional-de-Salud-2022-MINSAL-V8.pdf>. [Consultado: 06-oct-2023].
- [13] United Nations General Assembly, *Transforming Our World: The 2030 Agenda for Sustainable Development*. UN, 2015.
- [14] Alliance for Health Policy and Systems Research – WHO, *Systems Thinking for Health Systems Strengthening*, D. de Savigny y T. Adam, Eds., 2009. [En línea]. Disponible en: [http://apps.who.int/iris/bitstream/handle/10665/44204/9789241563895\\_eng.pdf](http://apps.who.int/iris/bitstream/handle/10665/44204/9789241563895_eng.pdf). [Consultado: 03-dic-2023].
- [15] K. Topuz, T. L. Urban, R. A. Russell y M. B. Yildirim, “Decision support system for appointment scheduling and overbooking under patient no-show behavior,” *Ann. Oper. Res.*, vol. 342, no. 1, pp. 845–873, nov. 2024, doi: 10.1007/s10479-023-05799-0.
- [16] S. A. Alowais et al., “Revolutionizing healthcare: The role of artificial intelligence in clinical practice,” *BMC Med. Educ.*, vol. 23, no. 1, p. 689, 2023, doi: 10.1186/s12909-023-04698-z.

[17] Biblioteca del Congreso Nacional de Chile, “Ley Chile - Resolución 277 EXENTA 03-JUN-2011 Ministerio de Salud, Subsecretaría de Salud Pública, Fondo Nacional de Salud,” 03-jun-2011. [En línea]. Disponible en: <https://www.bcn.cl/leychile>. [Consultado: 03-dic-2023].

[18] Ministerio de Salud – Gobierno de Chile, “Clasificación estadística internacional de enfermedades y problemas relacionados con la salud.” [En línea]. Disponible en: <https://repositoriodeis.minsal.cl/ContenidoSitioWeb2020/uploads/2018/03/CIE10-2015-Vol-2.pdf>. [Consultado: 14-abr-2024].

[19] World Health Organization, “International classification of diseases (ICD).” [En línea]. Disponible en: <https://www.who.int/es/standards/classifications/classification-of-diseases>. [Consultado: 13-abr-2024].

[20] Servicio de Salud Biobío, “Diseño de la Red Asistencial. Capítulo VI: Conclusiones diagnósticas.” [En línea]. Disponible en: [https://www.ssbiobio.cl/public/docs/disenio\\_de\\_la\\_red/7.%20Capitulo%20VI%20Informe%20Conclusiones%20diagnostico%20Diseno%20de%20Red,%20Servicio%20Salud%20Biobio.pdf](https://www.ssbiobio.cl/public/docs/disenio_de_la_red/7.%20Capitulo%20VI%20Informe%20Conclusiones%20diagnostico%20Diseno%20de%20Red,%20Servicio%20Salud%20Biobio.pdf). [Consultado: 09-may-2025].

[21] Biblioteca del Congreso Nacional de Chile, “Medición y reportes de la lista de espera No GES para atención en salud: reducción de cuentas públicas en Chile y buenas prácticas en países OCDE.” [En línea]. Disponible en: [https://obtienearchivo.bcn.cl/obtienearchivo?id=repositorio/10221/37106/1/BCN\\_Rendicion\\_Publica\\_de\\_Listas\\_Espera\\_en\\_Salud\\_\\_final2.pdf](https://obtienearchivo.bcn.cl/obtienearchivo?id=repositorio/10221/37106/1/BCN_Rendicion_Publica_de_Listas_Espera_en_Salud__final2.pdf). [Consultado: 09-may-2025].

[22] Hospital de Coquimbo, “Manual proceso de agendamiento,” Servicio de Salud Coquimbo, Coquimbo, Chile, 2019. [En línea]. Disponible en: <https://www.hospitalcoquimbo.cl/wp-content/uploads/2019/10/16300.pdf>.

[23] Hospital de Peñaflor, “Manual de agendamiento de especialidades,” Servicio de Salud Metropolitano Occidente, Peñaflor, Chile, 2019 [act. 2022]. [En línea]. Disponible en: <https://www.hospitalpenaflor.gov.cl/HP-MANUAL%20DE%20AGENDA%20ACTUALIZADA.pdf>.

[24] Hospital de La Serena, “Manual proceso de agendamiento,” Hospital de La Serena, La Serena, Chile, 2019. [En línea]. Disponible en: <https://www.hospitalserena.cl/transparencia/publicaciones/manualagendamiento.pdf>.

[25] Hospital de Ovalle, “Manual de agendamiento 2019,” Hospital de Ovalle, Ovalle, Chile, 2019. [En línea]. Disponible en: <https://www.hospitaldeovalle.cl/wp-content/uploads/2019/10/MANUAL-DE-AGENDAMIENTO-2019-1.pdf>.

[26] Instituto Traumatológico “Dr. Teodoro Gebauer W.,” “Manual de procedimientos agenda médica,” Servicio de Salud Metropolitano Central, Santiago, Chile, 2018. [En línea]. Disponible en: <https://www.intraumatologico.cl/files/Gobierno%20Transparente/Documentos/M anual%20de%20Procedimientos%20Agenda%20Medica.pdf>.

[27] R. K. Mishra, R. Kumar, A. Kapoor y P. Kumar, “Logarithmic adjustment in data science applications,” en *Proc. Int. Conf. Computational Intelligence and Data Science (ICCIDS 2019)*, vol. 43, Springer, 2020, pp. 489–497. [En línea]. Disponible en: [https://link.springer.com/chapter/10.1007/978-3-319-27104-0\\_43](https://link.springer.com/chapter/10.1007/978-3-319-27104-0_43).

[28] R. Cook, S. Sinha, D. Murphy y E. McDonald, “Log transformation in medical research: A methodological review,” *BMC Med. Res. Methodol.*, vol. 17, no. 1, pp. 1–10, oct. 2017. [En línea]. Disponible en: <https://bmcmmedresmethodol.biomedcentral.com/articles/10.1186/s12874-017-0322-8>.

[29] J. A. O’Brien y G. M. Marakas, *Management Information Systems*, 10th ed. New York, NY, USA: McGraw-Hill, 2011.

[30] IBM, “What is machine learning?” [En línea]. Disponible en: <https://www.ibm.com/topics/machine-learning>. [Consultado: 13-abr-2024].

[31] D. J. Kelleher y B. Tierney, *Ciencia de datos (MIT Press / Conocimientos Esenciales)*, Ediciones UC, 2021.

- [32] Elsevier, “Inteligencia artificial en entornos sanitarios: Tipos de algoritmos de ‘machine learning’.” [En línea]. Disponible en: <https://www.elsevier.com/es-es/connect/inteligencia-artificial-en-entornos-sanitarios-tipos-de-algoritmos-de>. [Consultado: 14-abr-2024].
- [33] IBM Data & AI Team, “10 everyday machine learning use cases,” IBM Blog. [En línea]. Disponible en: <https://www.ibm.com/blog/10-everyday-machine-learning-use-cases>. [Consultado: 14-abr-2024].
- [34] C. Aracena, F. Villena, F. Arias y J. Dunstan, “Aplicaciones de aprendizaje automático en salud,” *Rev. Méd. Clín. Las Condes*, vol. 33, no. 6, pp. 568–575, 2022.
- [35] M. J. Taboada Iglesias y A. Gómez-Pérez, “Sistemas basados en reglas,” en *Inteligencia artificial: métodos, técnicas y aplicaciones*, J. T. Palma Méndez y R. Marín Morales, Eds., Madrid, España: Facultad de Informática (UPM), 2008, p. 1022.
- [36] J. Durkin, *Expert Systems: Design and Development*. New York, NY, USA: Macmillan, 1994.
- [37] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, 3rd ed. Harlow, U.K.: Addison Wesley, 2011.
- [38] J. L. Moya-Rodríguez, A. M. Becerra-Ferreiro y C. A. Chagoyén-Méndez, “Utilización de sistemas basados en reglas y en casos para diseñar transmisiones por tornillo sinfín,” *Ing. Mecánica*, vol. 15, no. 1, pp. 1–9, 2012.
- [39] Khan Academy, “Usar heurísticas.” [En línea]. Disponible en: <https://es.khanacademy.org/computing/ap-computer-science-principles/algorithms-101/solving-hard-problems/a/using-heuristics>. [Consultado: 14-abr-2024].

[40] Z. A. Abdalkareem, A. Amir, M. A. Al-Betar, P. Ekhan y A. I. Hammouri, "Healthcare scheduling in optimization context: A review," *Health Technol.*, vol. 11, no. 3, pp. 445–469, may. 2021.

[41] Python Software Foundation, "BeginnersGuide/Overview - Python Wiki." [En línea]. Disponible en: <https://wiki.python.org/moin/BeginnersGuide/Overview>. [Consultado: 14-abr-2024].

[42] Google, "Google Workspace Updates," *Google Workspace Updates*. [En línea]. Disponible en: <http://workspaceupdates.googleblog.com/>. [Consultado: 04-abr-2024].

[43] Google Workspace, "Soluciones empresariales para colaborar y optimizar operaciones," *Google Workspace*. [En línea]. Disponible en: <https://workspace.google.com/intl/es-419/business/>. [Consultado: 04-abr-2024].

[44] Google Workspace, *Google Workspace | Business Apps & Collaboration Tools*, 2016.

[45] Google, "Introducción: Integración de aplicaciones de terceros con Google Workspace." [En línea]. Disponible en: [https://support.google.com/a/answer/10010706?hl=es#apps\\_drive](https://support.google.com/a/answer/10010706?hl=es#apps_drive). [Consultado: 04-abr-2024].

[46] D. Greene, "Introducing Google Cloud," Google, 29-sep-2016. [En línea]. Disponible en: <https://blog.google/products/google-cloud/introducing-google-cloud/>. [Consultado: 07-ago-2024].

[47] Y. Bermúdez Colina, "Aplicaciones de programación lineal, entera y mixta," *Ing. Ind. Actualidad Nuevas Tendencias*, vol. 2, núm. 7, pp. 85–104, 2011. [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=215024822007>. [Consultado: 01-may-2024].

[48] University of Baltimore, "Modelos deterministas: Optimización lineal," 25-feb-1996. [En línea]. Disponible en: <https://home.ubalt.edu/ntsbarsh/business-stat/opre/spanishd.htm#rlp>. [Consultado: 01-may-2024].

- [49] G. Zucchi, M. Iori y A. Subramanian, "Personnel scheduling during COVID-19 pandemic," *Optim. Lett.*, vol. 15, no. 4, pp. 1385–1396, jun. 2021, doi: 10.1007/s11590-020-01648-2.
- [50] I. Tseremoglou, P. J. van Kessel y B. F. Santos, "A comparative study of optimization models for condition-based maintenance scheduling of an aircraft fleet," *Aerospace*, vol. 10, no. 2, art. 2, feb. 2023, doi: 10.3390/aerospace10020120.
- [51] S. Gestrelus, M. Aronsson y A. Peterson, "A MILP-based heuristic for a commercial train timetabling problem," *Transp. Res. Procedia*, vol. 27, pp. 569–576, ene. 2017.
- [52] Q. Liu, X. Li, L. Gao y J. Fan, "A multi-MILP model collaborative optimization method for integrated process planning and scheduling problem," *IEEE Trans. Eng. Manag.*, pp. 1–13, 2022, doi: 10.1109/TEM.2024.3364972.
- [53] N. T. J. Bailey, "A study of queues and appointment systems in hospital out-patient departments, with special reference to waiting-times," *J. R. Stat. Soc.*, vol. 14, núm. 2, pp. 185–199, 1952.
- [54] D. Gupta y B. Denton, "Appointment scheduling in health care: Challenges and opportunities," *IIE Trans.*, vol. 40, no. 9, pp. 800–819, jul. 2008, doi: 10.1080/07408170802165880.
- [55] A. Ala y F. Chen, "Appointment scheduling problem in complexity systems of the healthcare services: A comprehensive review," *J. Healthc. Eng.*, vol. 2022, p. e5819813, mar. 2022, doi: 10.1155/2022/5819813.
- [56] P. Rodó, "Proceso de Poisson," *Economipedia*. [En línea]. Disponible en: <https://economipedia.com/definiciones/proceso-de-poisson.html>. [Consultado: 04-oct-2023].

- [57] S. Srinivas y A. R. Ravindran, "Optimizing outpatient appointment system using machine learning algorithms and scheduling rules: A prescriptive analytics framework," *Expert Syst. Appl.*, vol. 102, pp. 245–261, jul. 2018, doi: 10.1016/j.eswa.2018.02.022.
- [58] A. Yinusa y M. Faezipour, "Optimizing healthcare delivery: A model for staffing, patient assignment, and resource allocation," *Appl. Syst. Innov.*, vol. 6, no. 5, p. 78, 2023, doi: 10.3390/asi6050078.
- [59] L. S. L. Bastos, J. F. Marchesi, S. Hamacher y J. L. Fleck, "A mixed integer programming approach to the patient admission scheduling problem," *Eur. J. Oper. Res.*, vol. 273, no. 3, pp. 831–840, mar. 2019.
- [60] R. Alizadeh, J. Rezaeian, M. Abedi y R. Chiong, "A modified genetic algorithm for non-emergency outpatient appointment scheduling with highly demanded medical services considering patient priorities," *Comput. Ind. Eng.*, vol. 139, p. 106106, ene. 2020, doi: 10.1016/j.cie.2019.106106.
- [61] N. Campana, G. Zucchi, M. Iori, C. Magni y A. Subramanian, "An integrated task and personnel scheduling problem to optimize distributed services in hospitals," en *Proc. 23rd Int. Conf. Enterprise Information Systems*, Online Streaming, SCITEPRESS, 2021, pp. 463–472.
- [62] L. Wang, X. Zhao y P. Wu, "Large-scale emergency medical services scheduling during the outbreak of epidemics," *Ann. Oper. Res.*, vol. 348, no. 1, feb. 2023, doi: 10.1007/s10479-023-05459-7.
- [63] J. Jlassi, I. Rekik, S. Elloumi y H. Chabchoub, "Genetic algorithm for patients scheduling in emergency department: A case study," *Int. J. Supply Oper. Manag.*, vol. 10, no. 4, pp. 439–455, 2023, doi: 10.22034/ijssom.2023.109945.2766.
- [64] Google Workspace, "Soluciones de asistencia sanitaria e innovación en ciencias biológicas," *Google Workspace*. [En línea]. Disponible en: <https://workspace.google.com/intl/es/industries/healthcare/>. [Consultado: 04-abr-2024].

[65] S. Datta et al., “Healthcare API: Transforming medical research with Google Cloud,” *BMC Med. Inform. Decis. Mak.*, 2023.

[66] P. Ruamviboonsuk et al., “Real-time diabetic retinopathy screening by deep learning in a multisite national screening programme,” *Lancet Digit. Health*, vol. 4, no. 6, 2022, doi: 10.1186/s12911-023-02206-0.

[67] R. Guido, G. Ielpa y D. Conforti, “Scheduling outpatient day service operations for rheumatology diseases,” *Flex. Serv. Manuf. J.*, vol. 32, no. 1, pp. 102–128, 2020.

[68] D. Pérez Aguada, M. Milanés Luque, O. Mar Cornelio y A. Orellana García, “Diseño de sistema basado en reglas para apoyar la toma de decisiones de la población en la obtención de los medicamentos,” *RCIM*, vol. 15, no. 1, 2023, doi: 10.5585/rgss.v1i2.28.



[69] S. J. Osheroff, E. M. Pifer, M. H. Teich et al., *Improving Outcomes with Clinical Decision Support: An Implementer’s Guide*. Chicago, IL, USA: HIMSS, 2012.

[70] A. G. Owasis y M. I. Nithya, “Artificial intelligence in disease diagnosis: A systematic literature review,” *J. Ambient Intell. Hum. Comput.*, vol. 14, no. 7, pp. 8459–8486, 2023, doi: 10.1007/s12652-021-03612-z.

[71] Y. Zhang, X. Li y Z. Wang, “Domain-aware adaptive logarithmic transformation,” *Electronics*, vol. 12, no. 6, p. 1318, mar. 2023. [En línea]. Disponible en: <https://www.mdpi.com/2079-9292/12/6/1318>. [Consultado: 26-sep-2024].

[72] R. Abu Khurma, E. Alhenawi, M. Braik, F. A. Hashim, A. Chhabra y P. A. Castillo, “A bio-medical snake optimizer system driven by logarithmic surviving global search for optimizing feature selection and its application for disorder recognition,” *arXiv preprint arXiv:2404.07216*, 2024. [En línea]. Disponible en: <https://arxiv.org/pdf/2404.07216v1.pdf>. [Consultado: 26-sep-2024].

**Anexo A. APROBACIÓN COMITÉ ÉTICO CIENTÍFICO**  
**A.1. Información desde epicrisis**

---

A continuación, se presentan los documentos de aprobación del Comité Ético Científico del Servicio de Salud Talcahuano para adquirir la información de las epicrisis desde la base de datos del Servicio de Medicina Interna del Hospital Las Higueras de Talcahuano.



## Anexo 9.1. Aprobación de uso de base de datos del Servicio de Medicina Interna - Página 1.

Servicio de Salud Talcahuano  
Hospital Las Higueras  
Unidad de Apoyo a la Investigación Biomédica  
PSK/CAL/ipl



ORD. N° 002366 04.04.24  
ANT: Acta sesión ordinaria N°15/28.03.2024 CEC\_SST  
MAT: AUTORIZA TRABAJO DE INVESTIGACIÓN

DE : DRA. PATRICIA SÁNCHEZ KRAUSE  
DIRECTORA HOSPITAL LAS HIGUERAS  
A : DRA. ROSA FIGUEROA  
INVESTIGADORA RESPONSABLE

Estimada Investigadora:

Junto con saludar, es grato dirigirme a Ud., para informarle que habiendo completado los requisitos administrativos y la revisión ética del estudio, según Acta N° 15 de la sesión ordinaria del día 28.03.2024 del Comité Ético Científico del Servicio Salud Talcahuano, que aprueba el Trabajo de Investigación: **"Propuesta de optimización del agendamiento de citas médicas post alta, a partir de una base de datos de epicrisis del Servicio de Medicina Interna del Hospital Las Higueras"**, esta Directora:

1. Autoriza el inicio de las actividades contempladas, en su Investigación, a partir de esta fecha.
2. Ratifica la autorización de uso de base de datos anonimizada de mi Ord. N°1962 del 14.03.2024
3. Finalmente, solicito a UD., mantener informada a esta Dirección del avance de la investigación que dirige, especialmente, en casos de eventos adversos o desviaciones de Protocolo. Además de hacer llegar a esta Dirección una copia del Informe Final de su trabajo.

Sin otro particular y deseándole éxito en la investigación que dirigirá, le saluda muy cordialmente,



DRA. PATRICIA SÁNCHEZ KRAUSE  
DIRECTORA  
HOSPITAL LAS HIGUERAS

Distribución:

- La indicada
- Jefe Servicio Medicina Interna
- Comité Ético Científico del Servicio Salud Talcahuano
- Unidad de Apoyo a la Investigación
- Oficina de Partes

DSFH 4022

1

## Anexo 9.2. Aprobación de uso de base de datos del Servicio de Medicina Interna - Página 2.



ACTA N° \_\_\_\_\_15\_\_\_\_\_ /

28 MAR 2024

**ACTA DE EVALUACION  
PROYECTO DE INVESTIGACIÓN**

El Comité Ético Científico de Servicio de Salud Talcahuano, acreditado y cumpliendo con las Buenas Prácticas Clínicas, conformado por:

- Dra. Patricia Marcela Cortés Jofré, Epidemióloga Clínica, Químico Farmacéutico, Dirección Servicio de Salud Talcahuano, Presidenta Comité Ético Científico SST.
- D. Luis Mauricio Bravo Espinoza, Abogado, Dirección Servicio de Salud Talcahuano, Vicepresidente Comité Ético Científico SST.
- Dra. Natalia Marín Neira, Médico, Auditora Dirección Servicio de Salud Talcahuano.
- Dr. Wladimir Hermosilla Rubio, Médico Psiquiatra, Hospital Las Higueras.
- Dr. Reinaldo Neira Charlin, Médico Psiquiatra, Hospital Penco-Lirquén.
- Dr. Rodrigo Concha Navarrete, Médico, Atención Abierta, Hospital de Tomé.
- Dr. Jaime Quintana Vaccaro, Médico, Hospital Las Higueras.
- Dra. Liliana Lamperti Fernández, Bioquímico, Académico Depto. Bioquímica e Inmunología, Facultad de Farmacia, Universidad de Concepción.
- D. Adriana Ribeiro Alves, Abogada, Vicerrectoría de Investigación y Desarrollo, Universidad de Concepción.
- Dra. María Belén Ortega Senet, Trabajador Social, Académico Facultad de Comunicación, Historia y Cs Sociales Universidad Católica Santísima Concepción.
- D. Mariana Flores Mora, Voluntaria Dama de Rojo Hospital Las Higueras.
- D. Olivia Bahamondes Pedreros, Trabajadora Social, secretaria ejecutiva Comité Ético Científico SST.

En sesión extraordinaria de fecha 28 de marzo del 2024, el Comité Ético Científico de Servicio de Salud Talcahuano, habiéndose constituido el Quórum según Rex N° 1149 y Posterior Modificación Rex N°1602 ha analizado los documentos recepcionados el 19.03.2024, correspondientes a solicitud de evaluación de su trabajo de investigación.

Por lo anteriormente señalado y por la mayoría absoluta de sus miembros se Aprueba por 364 días el trabajo de investigación, denominado: "Propuesta de optimización del agendamiento de citas médicas post alta, a partir de una base de datos de epicrisis del Servicio de Medicina Interna del Hospital Las Higueras", cuya investigadora principal es D. Rosa Figueroa.

Dentro de este periodo, el estudio podrá ser sujeto de seguimiento.

Se deja estipulado que ningún integrante del Comité se declaró en conflicto de interés en este estudio.

Además, el comité solicita:

1. Informar en forma frecuente de su estado de desarrollo, como también de cualquier publicación o presentación de progresos que de él se genere.

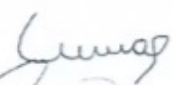


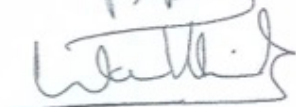

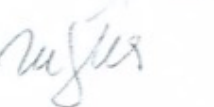
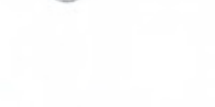

C/C.

- Investigador Principal
- Directora Hospital Las Higueras
- Archivo Comité Ético Científico SST

Anexo 9.3. Aprobación de uso de base de datos del Servicio de Medicina Interna - Página 3.

Lista de Asistencia Reunión Extraordinaria CEC SST

Jueves 28 de marzo de 2024

Natalia Manríquez	
Jaime Quiroga	
Olivia Bohamondes P.	
Patricio Bravo E.	
Marcela Cortés S.	
Wendy Henkel Ríos	
Natalya Cordero	
Mariana Flores Umana	



## **A.2. Generación conjunto de datos sintéticos**

Aquí se presentan los documentos de aprobación del Comité Ético Científico del Servicio de Salud Talcahuano para la generación del conjunto de datos sintético para la validación del modelo MILP, a partir de la base de datos entregado por el Servicio de Medicina Interna del Hospital Las Higueras de Talcahuano.



## Anexo 9.4. Aprobación para generación de datos sintéticos - Página 1.



ACTA N° \_\_\_\_\_ 21 \_\_\_\_\_ /

24 ABR 2025

### ACTA DE EVALUACION APRUEBA ENMIENDA N°1 PROYECTO DE INVESTIGACIÓN

El Comité Ético Científico de Servicio de Salud Talcahuano, acreditado y cumpliendo con las Buenas Prácticas Clínicas, conformado por:

- **Dra. Patricia Marcela Cortés Jofré**, Epidemióloga Clínica, Químico Farmacéutico, Dirección Servicio de Salud Talcahuano, Presidenta Comité Ético Científico SST.
- **D. Luis Mauricio Bravo Espinoza**, Abogado, Dirección Servicio de Salud Talcahuano, Vicepresidente Comité Ético Científico SST.
- **Dra. Natalia Marín Neira**, Médico, Auditora Dirección Servicio de Salud Talcahuano.
- **Dr. Wladimir Hermosilla Rubio**, Médico Psiquiatra, Hospital Las Higueras.
- **Dr. Reinaldo Neira Charlín**, Médico Psiquiatra, Hospital Penco-Lirquén.
- **Dr. Rodrigo Concha Navarrete**, Médico, Atención Abierta, Hospital de Tomé.
- **Dr. Jaime Quintana Vaccaro**, Médico, Hospital Las Higueras.
- **Dra. Liliana Lamperti Fernández**, Bioquímico, Académico Depto. Bioquímica e Inmunología, Facultad de Farmacia, Universidad de Concepción.
- **D. Adriana Ribeiro Alves**, Abogada, Vicerrectoría de Investigación y Desarrollo, Universidad de Concepción.
- **Dra. María Belén Ortega Senet**, Trabajador Social, Académico Facultad de Comunicación, Historia y Cs Sociales Universidad Católica Santísima Concepción.
- **D. Mariana Flores Mora**, Voluntaria Dama de Rojo Hospital Las Higueras.
- **D. Olivia Bahamondes Pedreros**, Trabajadora Social, secretaria ejecutiva Comité Ético Científico SST.

En sesión ordinaria de fecha 24 de abril del 2025, el Comité Ético Científico de Servicio de Salud Talcahuano, habiéndose constituido el Quórum según Rex N° 1149 y Posterior Modificación Rex N°1602, ha analizado su carta recepcionada el 14 de abril de 2025, correspondiente a:

- Solicitud evaluación Enmienda N°1 del Trabajo de investigación.

Por lo anteriormente señalado y por la mayoría absoluta de sus miembros se **Aprueba Enmienda N°01** al trabajo de investigación, denominado: "Propuesta de optimización del agendamiento de citas médicas post alta, a partir de una base de datos de epicrisis del Servicio de Medicina Interna del Hospital Las Higueras", cuya investigadora principal es Dra. Rosa Figueroa.

Se deja estipulado que ningún integrante se declaró en conflicto de interés en este estudio.

*Dra. Marcela Cortés Jofré*  
Presidenta Comité Ético Científico SST.

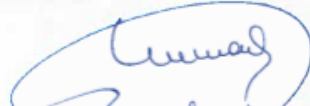

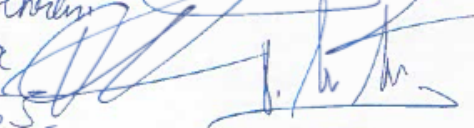


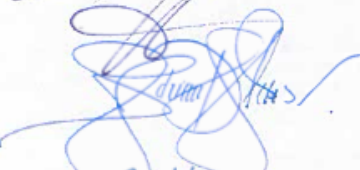


C/C.

- Investigador Principal.
- Directora Hospital Las Higueras
- Archivo Comité Ético Científico SST

Anexo 9.5. Aprobación para generación de datos sintéticos - Página 2.

Lista de Asistencia CEC SST

Jueves 24 de abril de 2025


Marcialia Maná	
Ronald G. Ruiz Chelín	
Jairo Recarte	
Morice la Costa	
Ricardo Carter Velásquez	
Rodrigo Cordero	
Adriana Espinoza	
Mariana Flores Umana	




**Anexo B. Gráficos para elección del percentil prioritario**

Aquí se presentan los gráficos de cada uno de los escenarios de evaluación y el comportamiento de la distribución de puntajes y curva CDF para encontrar el mejor percentil de corte según los puntajes de los pacientes y diferenciar a los pacientes con prioridad clínica.


**Anexo 9.6. Distribución puntajes y curva CDF - E1**




**Anexo 9.7. Distribución puntajes y curva CDF - E2**




**Anexo 9.8. Distribución puntajes y curva CDF - E3**




**Anexo 9.9. Distribución puntajes y curva CDF - E4**




**Anexo 9.10. Distribución puntajes y curva CDF - E5**




**Anexo 9.11. Distribución puntajes y curva CDF - E6**




**Anexo 9.12. Distribución puntajes y curva CDF - E7**




**Anexo 9.13. Distribución puntajes y curva CDF - E8**




**Anexo 9.14. Distribución puntajes y curva CDF - E9**




**Anexo 9.15. Distribución puntajes y curva CDF - E10**



**Anexo 9.16. Distribución puntajes y curva CDF - E11**




**Anexo 9.17. Distribución puntajes y curva CDF - E12-14**




### Anexo C. Ocupaciones horarias de bloque y día por escenarios


En las siguientes figuras se presenta la distribución horaria por bloque y día para cada uno de los escenarios evaluados. Estas visualizaciones permiten observar el comportamiento del modelo frente a distintos niveles de demanda y capacidad, evidenciando cómo ajusta la compactación de las agendas, la holgura intra-día y la utilización de bloques horarios disponibles. Cada gráfico corresponde a un heatmap generado automáticamente al finalizar la ejecución del modelo, donde las celdas con mayor intensidad indican bloques horarios más utilizados. Estas imágenes complementan el análisis de los KPIs y facilitan la interpretación cualitativa de los resultados obtenidos.




Anexo 9.18. Ocupación horaria por bloque y día - E3




**Anexo 9.19. Ocupación horaria por bloque y día - E4**




**Anexo 9.20. Ocupación horaria por bloque y día - E5**




**Anexo 9.21. Ocupación horaria por bloque y día - E6**



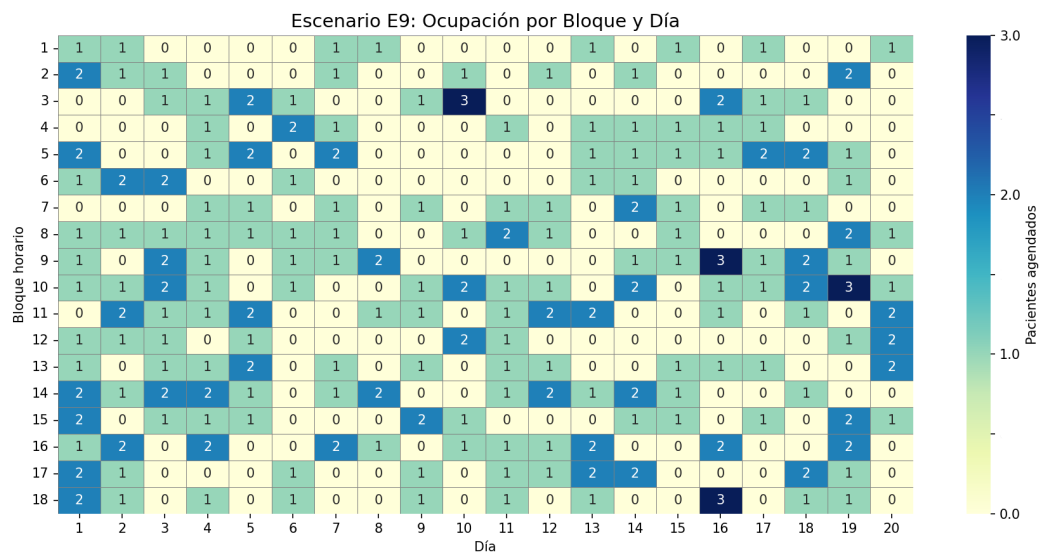
**Anexo 9.22. Ocupación horaria por bloque y día - E7**



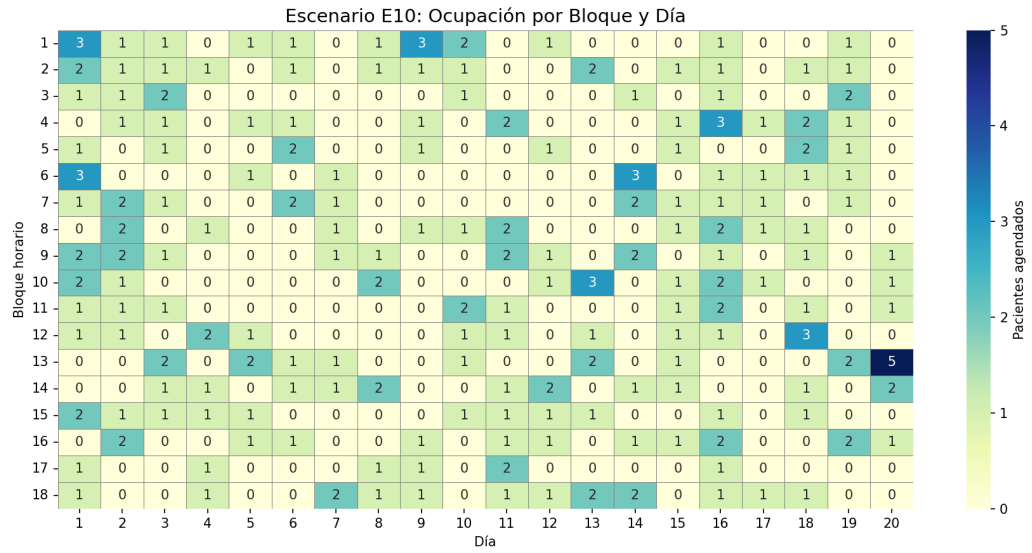
**Anexo 9.23. Ocupación horaria por bloque y día - E8**




**Anexo 9.24. Ocupación horaria por bloque y día - E9**




**Anexo 9.25. Ocupación horaria por bloque y día - E10**




**Anexo 9.26. Ocupación horaria por bloque y día - E11**



**Anexo 9.27. Ocupación horaria por bloque y día - E12**



**Anexo 9.28. Ocupación horaria por bloque y día - E13**



**Anexo 9.29. Ocupación horaria por bloque y día - E14**

