

**Modelo de optimización para la planeación de recursos en un departamento de
emergencia considerando el nivel de criticidad de los pacientes**

Trabajo de investigación para optar al título de Magister en Ingeniería Industrial

Dilan Jhoanny Mogollón Carreño

Director:

Edwin Alberto Garavito Hernández

Magíster en Ingeniería Industrial

Codirectora:

Laura Yeraldín Escobar Rodríguez

Magíster en Ingeniería Industrial

Grupo de Investigación:

Optimización y Organización de Sistemas Productivos, Administrativos y Logísticos

(OPALO)

Universidad Industrial de Santander

Escuela de Estudios Industriales y Empresariales

Maestría en Ingeniería Industrial

Bucaramanga

2025

Dedicatoria

A mis padres Iván y Libia.

Si pudimos.

Agradecimientos

A mis padres, por darme palabras de aliento cuando sentía que no podía.

A mi amiga, mi ejemplo y mi guía, la profesora Laura Escobar por confiar desde el primer momento en mí y enseñarme a confiar en mí mismo, por su apoyo y por ayudarme a cumplir mis sueños. Gracias por eso profe.

Al profe Edwin Garavito por su apoyo, sus enseñanzas y orientación en estos dos años, por darme el voto de confianza y por su ayuda en mi crecimiento académico y personal.

A mi amigo y profe Edgar por acompañarme en momentos académicos y personales, por orientarme y darme palabras de aliento, por abrirme su confianza y enseñanzas. Gracias profe.

A mi amiga Danna, por sus ocurrencias y su apoyo incondicional en todo.

A ti, que me enseñaste lo hermosa que puede ser la vida.

Al grupo OPALO que se convirtió en mi segunda familia.

A todas las personas que incidieron en mi crecimiento personal y académico, gracias.

Tabla de contenidos

1.Objetivos	13
1.1.Objetivo General.....	13
1.2.Objetivos Específicos.....	13
2.Planteamiento y justificación del problema.....	14
3.Proposiciones	16
4.Metodología.....	17
4.1.Revisión de literatura	17
4.2.Análisis, tratamiento de datos y caracterización del sistema.....	18
4.3.Modelo matemático	19
4.4.Análisis de sensibilidad.....	20
5.Revisión de literatura	21
5.1.Planeación de recursos.....	21
5.1.1.Caracterización de la demanda de pacientes.....	27
5.1.2.Optimización de recursos.....	30
5.2.Discusión de la revisión.....	35
6.Marco de referencia	37
6.1.Marco teórico	37
6.1.1.Modelo Optimización-Simulación.....	37
6.1.2.Planeación de recursos sanitarios.....	37
6.1.3.Triage	37
6.1.4.Ruta clínica	37

6.2.Marco conceptual..... 38

6.2.1.Análisis de criticidad..... 38

6.2.2.Requerimiento de tratamientos 38

6.3. Marco legal 38

6.3.1.Ley 100 de 1993..... 38

6.3.2.Resolución 3100 de 2019..... 38

6.3.3.Resolución 5596 de 2015..... 38

7.Análisis y caracterización del sistema 39

8.Formulación de un Modelo Matemático..... 50

8.1.Descripción del modelo matemático..... 51

8.1.1.Conjuntos 51

8.1.2.Parámetros del modelo..... 51

8.1.3.Variables de decisión..... 52

8.1.4.Función objetivo 53

8.1.5.Restricciones del modelo 53

8.2.Obtención de soluciones a partir del modelo..... 57

9.Diseño experimental y análisis de resultados 64

9.1.Diseño experimental 64

9.2.Análisis de resultados 66

9.2.1.Análisis dentro del escenario 67

9.2.2.Análisis entre escenarios..... 71

10.Conclusiones 73

11.Futuras investigaciones 75

Referencias Bibliográficas 76

Lista de figuras

Figura 1. Revisión de literatura.....	17
Figura 2. Procesamiento de datos	18
Figura 3. Fases para formular un modelo de optimización.....	19
Figura 4. Caracterización de recursos en centros de salud	22
Figura 5. Problemas desde la investigación de operaciones	24
Figura 6. Dispersión, tiempo entre llegadas.....	40
Figura 7. Frecuencia de pacientes por nivel de triage.....	42
Figura 8. Frecuencia de pacientes por hora del día.....	43
Figura 9. Triage IV	45
Figura 10. Distribución mezclada	45
Figura 11. Forma gráfica del funcionamiento de restricciones 7 a 10	55
Figura 12. Forma gráfica del funcionamiento de restricciones 11 a 14	55
Figura 13. Forma gráfica del funcionamiento de restricciones 15 y 16.....	56
Figura 14. Análisis de escenarios.....	60
Figura 15. Costos de personal vs costos de tiempo de espera.....	61
Figura 16. Comportamiento de costos totales.....	62
Figura 17. Escenarios diseñados	66
Figura 18. Comparación de escenarios	69
Figura 19. Número de recursos de tipo humano	70
Figura 20. Análisis entre escenarios	71

Lista de tablas

Tabla 1. Perspectiva del nivel de decisión en el área de salud	23
Tabla 2. Medidas de rendimiento en EDs.....	26
Tabla 3. Métodos para pronosticar demanda.....	28
Tabla 4. Métodos para predecir demanda.....	30
Tabla 5. Técnicas de Simulación.....	31
Tabla 6. Modelos de simulación.....	32
Tabla 7. Tipo de programación matemática	33
Tabla 8. Modelos de programación matemática.....	34
Tabla 9. Bondad de ajuste, tiempo de registro y clasificación	41
Tabla 10. Bondad de ajuste, tiempo entre llegadas	44
Tabla 11. Parámetros distribución mezclada	46
Tabla 12. Actividades del sistema	48
Tabla 13. Características del equipo.....	57
Tabla 14. Simulación de datos.....	58
Tabla 15. Comparación de resultados.....	63
Tabla 16. Tamaño de instancias.....	64
Tabla 17. Diseño experimental.....	65
Tabla 18. Tiempo computacional	67

Resumen

Título del proyecto: Modelo de optimización para la planeación de recursos en un departamento de emergencia considerando el nivel de criticidad de los pacientes. *

Autor: Dilan Jhoanny Mogollón Carreño**

Palabras claves: Modelo matemático, Triage, Modelo de optimización, Planeación de recursos, Asignación de recursos, Departamentos de emergencia

Descripción:

Los sistemas de salud enfrentan desafíos a la hora de planificar y asignar los recursos debido a la incertidumbre relacionada con la llegada de pacientes sin cita previa. Esta situación es debido a la imposibilidad de anticipar el momento en el que un paciente llegará, así como las condiciones para definir el procedimiento necesario para su atención. Este problema se traduce directamente en altos tiempos de espera, saturación del departamento de emergencia (ED) y escasez en los recursos necesarios para un tratamiento oportuno. El hacinamiento de pacientes en los ED es consecuencia directa de una planeación de recursos deficiente (Graham et al.,2018), problema que ha sido tratado desde la caracterización y clasificación de pacientes en función de los niveles de gravedad asociados al triage.

En este trabajo, se propone un modelo de optimización de recursos en un departamento de emergencia. Para el desarrollo del modelo se definieron cuatro fases: la primera (1) asociada a una revisión de literatura, luego (2) definición de parámetros de entrada y análisis de datos para la construcción del modelo, seguido (3) el diseño del modelo de optimización que permite definir del número de personal necesario para dar tratamiento a un número de pacientes definido y finalmente (4) explorar el comportamiento del modelo desde la simulación de datos.

*Trabajo de grado

**Facultad de ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales

Director: M.Sc. Edwin Alberto Garavito Hernández

Codirectora: M.Sc. Laura Yeraldín Escobar Rodríguez

Abstract

Title: Optimization model for resource planning in an emergency department considering the criticality level of patients. *

Author: Dilan Jhoanny Mogollón Carreño**

Keywords: Mathematical model, Triage, Optimization model, Resource planning, Resource allocation, Emergency departments.

Description:

Health systems face challenges when planning and allocating resources due to the uncertainty related to the arrival of walk-in patients. This situation is due to the impossibility of anticipating when a patient will arrive, as well as the conditions to define the necessary procedure for their care. This problem translates directly into high waiting times, saturation of the emergency department (ED) and shortage of resources necessary for timely treatment. Patient overcrowding in EDs is a direct consequence of poor resource planning (Graham et al., 2018), a problem that has been addressed from the characterization and classification of patients based on severity levels associated with triage.

In this work, a model for resource optimization in an emergency department is proposed. For the development of the model, four phases were defined: the first (1) associated with a literature review, then (2) definition of input parameters and data analysis for the construction of the model, followed by (3) the design of the optimization model that allows defining the number of staff needed to treat a defined number of patients and finally (4) exploring the behavior of the model from the data simulation.

*Master thesis

**Faculty of Physico-Mechanical Engineering. School of Industrial and Business Studies

Advisor: M.Sc. Edwin Alberto Garavito Hernández

Advisor: M.Sc. Laura Yeraldín Escobar Rodríguez

Introducción

Los sistemas de salud constantemente presentan desafíos a la hora de planificar los requerimientos de recursos debido a la incertidumbre relacionada con la llegada de pacientes que no cuentan con cita previa. Esta situación se presenta de forma más recurrente en los servicios de urgencias, debido a la imposibilidad de anticipar el momento en el que un paciente llegará, así como las condiciones con las cuales se define el procedimiento necesario para su atención. Este problema se traduce directamente en altos tiempos de espera, saturación de los departamentos de emergencia, y escasez de recursos necesarios para un tratamiento oportuno.

Una consecuencia directa de una planeación deficiente de recursos es el hacinamiento de pacientes en los Departamentos de Emergencia (en adelante para referirse a departamentos de emergencia se usará ED por sus siglas en inglés correspondientes a Emergency Department) (Graham et al., 2018), problema que ha sido tratado desde la caracterización y clasificación de usuarios en función de niveles de complejidad junto con la identificación de variables demográficas (Qian et al., 2021; Zaerpour et al., 2020). La identificación de variables se hace con el fin de aumentar la precisión en la clasificación de pacientes y posteriormente generar una estimación del comportamiento de la demanda, es decir, el número de pacientes que ingresarán al sistema de urgencias.

A partir de lo anterior, se han diseñado diferentes modelos matemáticos y de simulación para la planeación de recursos y minimización de tiempos de espera, los cuales varían en su estructura dependiendo de las medidas de desempeño a considerar. En primer lugar, los modelos matemáticos se han usado para el apoyo en la toma de decisiones, esencialmente buscando la asignación de recursos óptima, minimización de los tiempos de espera y costos asociados al servicio de cada paciente. Por otra parte, los modelos de simulación pretenden evaluar el nivel de

eficiencia de un sistema ED mediante la toma de decisiones desde el análisis de estadísticas y la caracterización del comportamiento del sistema.

En ese sentido, la presente investigación propone un modelo de optimización para la planeación y asignación de recursos en un departamento de emergencia considerando el nivel de criticidad de los pacientes (nivel de triage). Este trabajo permite aportar desde un punto de vista teórico escalable a la práctica considerando decisiones como:

- Número de personal requerido para dar atención médica.
- Secuenciación de pacientes en función de minimizar tiempos de espera

Finalmente, para validar el comportamiento del modelo, se realiza un análisis de sensibilidad a partir de técnicas de simulación.

Este documento se encuentra estructurado de la siguiente manera: en la sección 1 se encuentran los objetivos perseguidos en esta investigación. La sección 2 presenta el planteamiento y justificación del problema correspondiente al tema en cuestión. La sección 3 muestra las proposiciones planteadas con la investigación. La sección 4 presenta la metodología implementada en la investigación, las secciones 5,6,7 y 8 muestran a detalle lo mencionado en la metodología. Finalmente, las secciones 9 y 10 presentan las conclusiones y consideraciones para futuras investigaciones.

1. Objetivos

1.1.Objetivo General

Formular un modelo de optimización para la planeación de recursos en un departamento de emergencia considerando el nivel de criticidad de los pacientes.

1.2.Objetivos Específicos

- Caracterizar el problema de planeación de recursos a partir de una revisión de literatura para la identificación de estrategias de clasificación de pacientes, modelado y simulación.
- Caracterizar los requerimientos de tratamientos a partir del análisis de criticidad asociados en el triage.
- Desarrollar un modelo de optimización para la planeación de recursos de un Departamento de emergencia.
- Evaluar la sensibilidad del modelo de optimización a través de un análisis de escenarios usando técnicas de simulación.

2. Planteamiento y justificación del problema

Los modelos de optimización en el área de la investigación de operaciones son de gran ayuda para el diseño e implementación de estrategias que mejoren el rendimiento del sistema desde la toma de decisiones. En los centros de salud, específicamente en los EDs, es posible evidenciar una condición recurrente, el hacinamiento de pacientes, que se caracteriza por altos tiempos de espera y que, sumado a la incertidumbre de su llegada, genera desafíos importantes en los ejercicios de planeación de la capacidad y asignación de recursos de un sistema.

El hacinamiento es una consecuencia transversal en todas las áreas que componen el sistema de salud. La naturaleza incierta de la llegada de pacientes resulta un factor influyente, para ello se caracteriza la población dentro de los sistemas, recurrente (con cita previa) y no recurrente (Aboueljinane & Frichi, 2022), siendo estos últimos aquellos cuyo ingreso es por medio de la zona de urgencias, conocida como departamentos de emergencias. Es por esta razón que en los ED se presenta un reto mayor, ya que no se conoce con certeza el número de pacientes que ingresarán al sistema.

Los tiempos de espera desmedidos y la saturación del sistema, corresponden a consecuencias de los problemas de capacidad y disponibilidad de recursos. La planeación debe realizarse de manera eficiente desde la caracterización de pacientes, esto con la finalidad de identificar la asociación de recursos (humano y no humano) requeridos para dar tratamiento a las diferentes necesidades. Autores como Murphy et al., (2013) proponen el aumento de personal para suplir la falta de competencias del sistema; este enfoque analítico no resulta útil de aplicar en múltiples contextos debido a las restricciones de presupuesto que se tiene en un sistema de salud.

Los modelos analíticos no resultan ideales a nivel general al momento de planear recursos en los ED debido a que se basan en la subjetividad, por ello, la importancia de construir modelos

de Optimización- Simulación (O-S por sus siglas en inglés correspondientes a Optimization-Simulation) que incorporen directamente la planeación y asignación de recursos desde la consideración de los niveles de gravedad expresados en la zona de triage (para el contexto de Colombia se rige por la resolución 5596 de 2015 del ministerio de salud).

En ese sentido, soportado en literatura, con la presente investigación se busca formular un modelo de optimización que determinista que considere diferentes medidas de desempeño para la planeación de recursos en un ED, incorporando técnicas estadísticas para la caracterización de pacientes que harán uso de los diferentes tipos de recursos presentes en la zona de urgencias.

3. Propositiones

La investigación presente considera las siguientes proposiciones:

- Los modelos de optimización resultan útiles para apoyar la toma de decisiones en la planeación y asignación de recursos de los departamentos de emergencia a partir de la llegada irregular de pacientes.
- La caracterización de pacientes es un elemento esencial desde 2 aspectos: (1) el momento de llegada al ED y (2) el nivel de gravedad de gravedad que presenta al momento de ingresar al ED.
- El tiempo de espera de los pacientes aumenta en función de la poca disponibilidad de recursos.


4. Metodología

La presente sección describe la metodología llevada a cabo a lo largo de la investigación, esta se desarrolla con un enfoque positivista, el cual considera la objetividad de los resultados esperados en la investigación. La metodología se presenta en cuatro fases, cada una asociada a un objetivo específico presentados en la sección **1.2**.

4.1.Revisión de literatura

La revisión de literatura responde al cumplimiento del objetivo específico uno, el cual sigue la metodología planteada por Randolph, (2019) ilustrada en la **Figura 1**. La revisión persigue esencialmente tres aspectos, (1) la caracterización de los sistemas de salud, haciendo énfasis en los EDs considerando los recursos que forman parte de estos, destacando como aspecto esencial la caracterización de pacientes, siendo este el punto de partida para la planeación de recursos dentro de los EDs y las métricas de desempeño implementadas (**Tabla 2**), luego se enfoca en las maneras como se optimizan los recursos en EDs destacando dos elementos; (2) los modelos de simulación como segundo eje central de la revisión, destacando los más implementados en el campo de la salud junto con algunos de los trabajos encontrados a la fecha y por último (3) los modelos matemáticos que describen algunos de los modelos más implementados para la planeación de recursos, junto con algunas investigaciones encontradas a la fecha.

Figura 1.
Revisión de literatura



Nota: Adatado de Randolph, (2019)

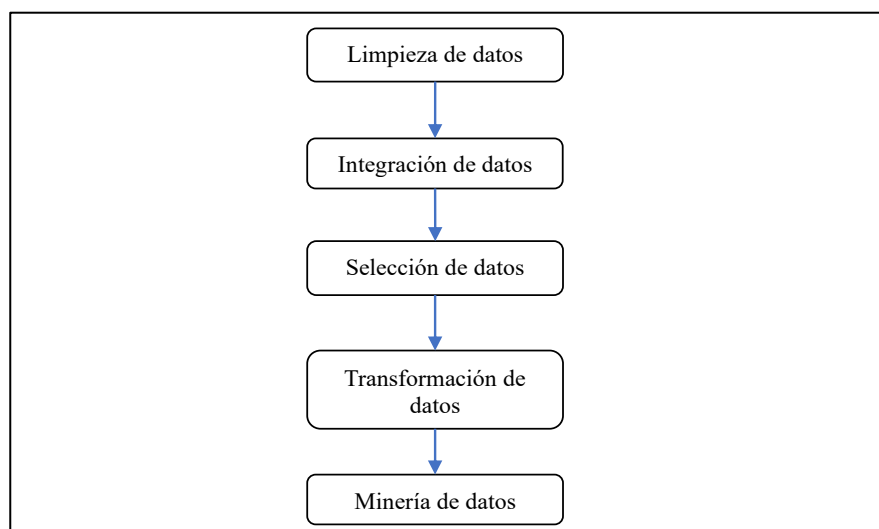
Teniendo clara la formulación del problema en función de los aspectos que se describen anteriormente, se procede a la recopilación de la información; para ello, se diseñó una búsqueda en bases de datos con el fin de encontrar investigaciones relevantes correspondientes al problema formulado, en el *Anexo A. Análisis bibliométrico* se describe a detalle la manera en la cual se recolecta y depura la información encontrada. La *sección 5* presenta los hallazgos hasta la fecha, estructurada y enfocada en los tres ejes temáticos mencionados anteriormente.

4.2. Análisis, tratamiento de datos y caracterización del sistema

Parte esencial al momento de intentar optimizar los recursos de un ED, es la caracterización de los requerimientos de tratamientos de los pacientes, para ello, es necesario identificar cada paciente en función de su nivel de criticidad (Triage) y los recursos asociados al procedimiento médico de este. Este apartado responde al objetivo específico dos, el cual es desarrollado mediante la metodología planteada por Han et al., (2012). La **Figura 2** describe los pasos a seguir para el tratamiento de datos.

Figura 2.

Procesamiento de datos



Nota: Adaptado de Han et al., (2012)

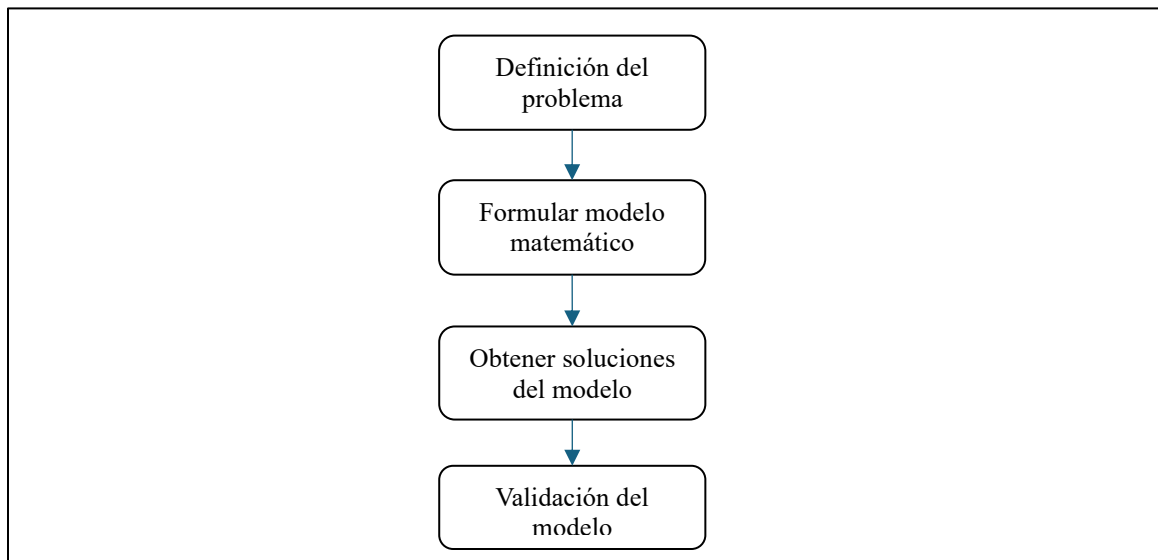
En esta sección se caracterizan varios elementos de los pacientes que son insumo para los parámetros que se usan en el modelo matemático, entre los cuales se tiene, la identificación de la ruta clínica de cada paciente, los recursos asociados a cada ruta, tiempos de atención en actividades, entre otros.

4.3. Modelo matemático

A partir de lo analizado y encontrado en la fase anterior, se construye un modelo matemático siguiendo la metodología definida por Hillier & Lieberman, (2010) la cual consta de manera general de cuatro aspectos, los cuales se muestran en la Figura 3.

Figura 3.

Fases para formular un modelo de optimización



Nota: Adaptado de Hillier & Lieberman, (2010)

Siguiendo la estructura propuesta en la **Figura 3**, el primer elemento se encuentra presente en las secciones explicadas con anterioridad. Una vez definido el problema en esta etapa se procede al planteamiento y validación del modelo matemático.

Para el desarrollo del modelo se identificaron elementos como:

- **Parámetros:** se identifica qué datos son necesarios para la construcción del modelo y definición de instancias.
- **Variables de decisión:** para el problema definido se establecen variables continuas que se asocian con el momento de inicio y fin en una actividad para cada paciente; variables enteras que definen el número de recursos que se necesitan para dar a atención a un número de pacientes definidos; variables binarias que ayudan a establecer la secuenciación entre pacientes y asignación a recursos.
- **Criterio de decisión:** se construye una función objetivo que busca minimizar el costo asociado al número de recursos involucrados en el sistema y el costo asociado al tiempo de espera.
- **Restricciones del modelo:** establecen las condiciones bajo las cuales funciona el sistema, tales como el tiempo máximo de espera hasta la primera visita de médico (Resolución 5596 de 2015) y tiempos de espera máximos a lo largo de todo el sistema.

4.4. Análisis de sensibilidad

Esta fase comprende la última etapa de la fase anterior asociada a la validación y experimentación a través del modelo. Para la validación se definen 7 instancias y 5 niveles (Escenarios) provenientes de literatura en donde se definen diferentes llegadas de pacientes en una jornada laboral, esto con el fin de evaluar el rendimiento del modelo (Harzi et al., 2017). Finalmente, se propone ver cómo se afecta el comportamiento del modelo al realizar un análisis de escenarios teniendo en cuenta el tiempo máximo del paciente en toda su ruta clínica bajo una de las instancias definidas. En esta fase se hizo uso de la licencia Campus Agreement con la que

cuenta la Universidad Industrial de Santander seleccionando el software Matlab¹ como entorno de ejecución del modelo.

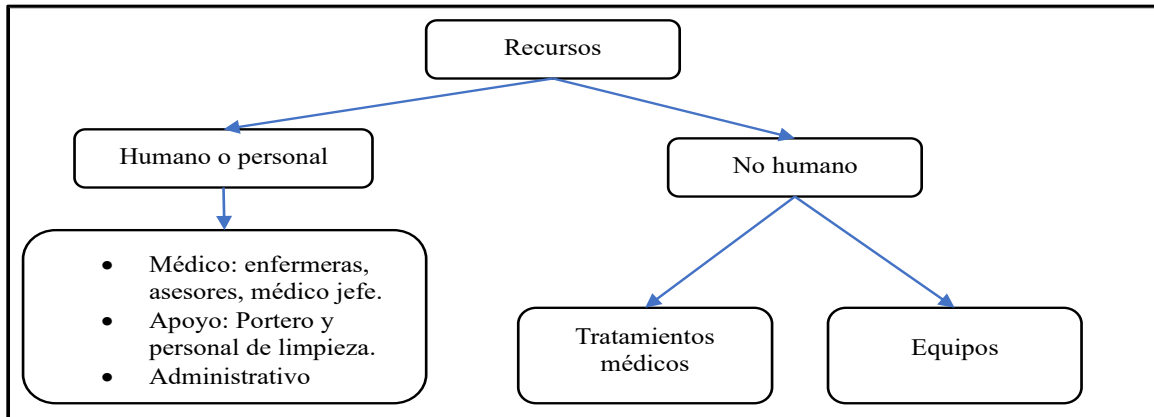
5. Revisión de literatura

Para el entendimiento de un sistema de salud es necesaria la caracterización de este, por ello, en esta sección se describe el sistema desde la revisión de literatura realizada, la cual se estructura de la siguiente manera: (1) Planeación de recursos en sistemas de salud, (2) técnicas para la categorización y estimación de la demanda de pacientes, (3) estrategias de modelado para abordar los desafíos asociados a la planeación de recursos y, (4) discusión de la revisión.

5.1. Planeación de recursos

La planeación de recursos en el sector de la salud se ha presentado como un tópico altamente estudiado a lo largo de los años. La diversificación de recursos en los centros asistenciales no son los mismos, esto lleva a que, desde la literatura, diversos autores los segmenten en dos grupos generales para facilitar su caracterización. Por un lado, se tienen los recursos de carácter humano, donde gran parte de la eficiencia se debe a la capacitación del personal médico; investigaciones como la de Murphy et al., (2013) plantea una lista con 150 competencias que evalúa el desempeño del personal médico. En contraparte se encuentran los recursos no humanos, que son aquellos que no involucran directamente al personal médico como ente principal; estos se asocian a los tratamientos prestados, disposición física del centro asistencial entre otros (Batljan & Lagergren, 2004; Birch et al., 2003; Ismail et al., 2014). La **Figura 4** muestra de manera esquemática lo mencionado anteriormente.

¹ Software comercial desarrollado para el cálculo numérico con lenguaje propio. Desarrollado por Mathworks y Clever Moler. Versión R2024b.

Figura 4.*Caracterización de recursos en centros de salud*

Nota: Adaptado de Batljan & Lagergren, (2004); Birch et al., (2003); Ismail et al., (2014); Murphy et al., (2013)

Como se menciona anteriormente los recursos específicos cambian dependiendo del centro asistencial que se tenga; sin embargo, es posible segmentarlos en dos grandes grupos. La caracterización es necesaria al momento de tomar decisiones por parte de los centros de salud, y estas decisiones impactan de una u otra forma dependiendo de la manera y estructura de la organización. Aboueljinane & Frichi, (2022) exponen como la interdependencia en departamentos puede afectar el rendimiento del sistema de salud en función de las decisiones que se toman; estos presentan el concepto de centralización, en el que la decisión tomada en un departamento afecta el funcionamiento de otros y descentralización como la toma de decisiones de manera independiente en cada departamento de un centro de salud.

Desde la perspectiva de la investigación de operaciones los niveles de decisión juegan un papel importante al momento de planear y asignar recursos en un sistema de salud; las decisiones de tipo estratégico caracterizadas por tomarse al inicio del horizonte de planeación en el aspecto hospitalario, han sido tomadas en su mayor medida desde modelos de simulación; por otro lado, las decisiones tácticas y operáticas, se orientan un poco más a decisiones apoyadas en modelos de

optimización (Stoeck & Mellouli, 2021). La **Tabla 1** describe algunos ejemplos en el área de salud en función de su nivel de decisión.

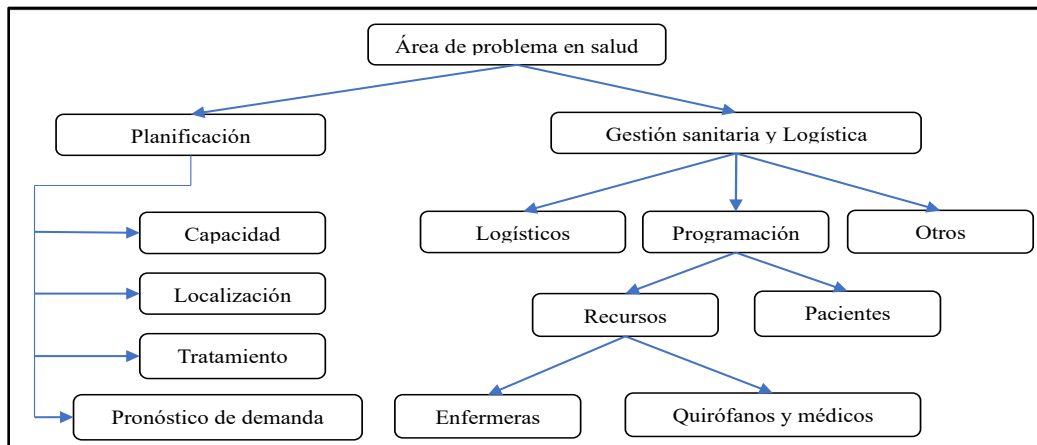
Tabla 1.
Perspectiva del nivel de decisión en el área de salud

<i>Tipo de</i>	<i>Descripción</i>	<i>Objetivo</i>
<u>Estratégica</u>	Son decisiones tomadas al inicio del horizonte de planeación, abarcando desde el principio hasta el final.	Planificación de capacidad
		Planificación de ambulancias
		Diseño de planta
		Dimensión de recurso humano
<u>Táctica</u>	Son de carácter intermedio a lo largo del tiempo, estas pueden variar meses después de tomarlas.	Despliegue de ambulancias
		Programación de personal
<u>Operativa</u>	Son aquellas tomadas de manera constante y recurrente, presentes en el corto plazo.	Envío de ambulancias
		Clasificación de triage en ED
		Política de recepción de ambulancias

Nota: Adaptado de Aboueljinane & Frichi, (2022)

En el área de investigación de operaciones se han presentado diferentes problemas a lo largo del tiempo, cada uno de ellos asociados a los niveles de decisión presentados en la **Tabla 1**. Desde esta perspectiva, la **Figura 5** muestra algunos de los problemas más estudiados desde esta perspectiva.

Figura 5.
Problemas desde la investigación de operaciones



Nota: Adaptado de Rais & Vianaa, (2011); Stoeck & Mellouli, (2021)

La **Figura 5** segmenta los problemas en investigación de operaciones en dos grupos principales: (1), los problemas asociados a la planificación se relacionan directamente a las decisiones de tipo estratégico y, (2) la gestión sanitaria y logística se vincula a las decisiones de tipo táctico y operativo. Los problemas de capacidad y localización se han trabajado desde la ubicación de centros de salud intentando minimizar costos de ubicación, mientras que el pronóstico de demanda se ha estudiado para identificar y delimitar la capacidad que puede llegar a tener un centro asistencial. La gestión sanitaria y logística en cada uno de sus tres subgrupos presenta diferentes aspectos, (1) los logísticos se asocian con ruteo en la distribución logística de medicamentos, (2) la programación de pacientes y recursos se realiza para la asignación de pacientes a recursos y programación de turnos en personal médico, (3) por último, cuando se hace referencia a “otros” son problemas menos estudiados pero que han cobrado relevancia, tales como el estudio y optimización de bancos de sangre, relacionados con la recolección, nivel de inventario y logística en la distribución de unidades de sangre (Rais & Vianaa, 2011).

A partir de lo anterior, en los sistemas de salud, Aboueljinane & Frichi, (2022) identifican cuatro unidades con problemas dentro de sus operaciones: (1) Servicio de emergencia, (EMS por sus siglas en inglés correspondiente a Emergency Medical Service) que se enfoca en como el servicio médico va al paciente y viceversa, (2) Departamentos de emergencia (EDs por sus siglas en inglés correspondiente a Emergency Department) caracterizada por la llegada incierta de pacientes, (3) Vía de atención de urgencias (ECP por sus siglas en inglés correspondiente a Emergency Care Pathway) es la ruta clínica que debe seguir un paciente para su tratamiento y por último, (4) Unidad de observación (OU por sus siglas en inglés correspondiente a Observation Unit) que es la unidad de cuidados a pacientes.

Siguiendo la idea de Aboueljinane & Frichi, (2022) con las unidades que presentan problemas y considerando el concepto de centralización expuesto con anterioridad, en adelante la presente revisión se centra en los EDs desde la consideración de que impactando esta unidad se impactan de manera simultánea las otras tres unidades, además, los EDs presentan la particularidad que el ingreso de pacientes es sin cita previa, incrementando la complejidad al momento planear y asignar recursos. Desde la investigación de operaciones se plantean diferentes métricas que permiten cuantificar el rendimiento de un ED. La **Tabla 2** muestra alguna de las más importantes identificadas desde literatura:

Tabla 2.
Medidas de rendimiento en EDs

Métrica/Objetivo	Descripción
<i>Duración de estancia (LOS)</i>	Tiempo que dura un paciente en el sistema.
<i>Tiempo puerta-médico (DTDT)</i>	Tiempo que transcurre desde la llegada del paciente y su primera evaluación.
<i>Tiempo de embarque (BT)</i>	Tiempo de un paciente para ser admitido en OU tras tener autorización.
<i>Ambulancias perdidas (LA)</i>	Proporción de ambulancias desviadas a otros centros por saturación.
<i>Tiempo total de espera (TWT)</i>	Hace referencia al tiempo total de espera del paciente, pero estos se desagregan en varios
<i>Disponibilidad del despachador (WT1)</i>	Tiempo entre llegada de la llamada del paciente al centro de llamadas EMS y la disponibilidad de un despachador para atender la llamada
<i>Asignación de ambulancia (WT2)</i>	Tiempo entre el final de la revisión de la llamada por parte del despachador y que una ambulancia esté disponible
<i>Registro de urgencias (WT3)</i>	Tiempo de llegada de un paciente a urgencias y la disponibilidad para registrarlo
<i>Triage (TW4)</i>	Tiempo entre el final del registro por parte del agente y que una enfermera de triage esté disponible para atenderlo
<i>Asignación de cama (WT5)</i>	Tiempo entre el final del triage por parte de la enfermera de triage hasta que una cama de ED esté disponible
<i>Consulta médica (WT6)</i>	Tiempo entre instalación del paciente en cama y el médico disponible para atenderlo.
<i>Pruebas de laboratorio (WT7)</i>	Tiempo entre la prescripción de las pruebas por el médico y que el laboratorio esté disponible
<i>Comprobación de resultados (WT8)</i>	Tiempo entre la realización de todas las pruebas y que un médico verifique los resultados
<i>Carga de trabajo (WL)</i>	Hace referencia a la carga de trabajo aplicada al personal medico
<i>Programación de horarios (TS)</i>	Hace referencia a los horarios designados a cada médico y enfermera en función de su disponibilidad
<i>Costo Total (TC)</i>	Hace referencia al costo global luego de la planeación de recursos.
<i>Número de camas (NB)</i>	Hace referencia al número de camas que se asignan a los pacientes.
<i>Length of stay(LOS), Door-to-Doctor(DTDT), Boarding time (BT), Lost Ambulances(LA), Patient's total waiting time(TWT), Dispatcher availability(TW1), Ambulance assignment(TW2), ED registration (TW3), Triage(TW4), Bed assignment(TW5), Physician consultation(TW6), Laboratory and radiological test (TW7), Physician check of results(TW8), Work load(WL), Time Scheduling(TS), Total Cost(TC), Number Beds(NB)</i>	
Nota: Información adapta de Aboueljinane & Frichi, (2022); Mizan & Taghipour, (2022)	

En un contexto práctico los ED planifican los recursos en función de la demanda y asociado a la incertidumbre de esta, es allí donde se enfoca gran parte de los esfuerzos (Munadvalli et al.,

2017). Para la planeación y asignación de recursos en EDs, Stoeck & Mellouli (2021) definen dos elementos necesarios, (1) la demanda que se relaciona o es tratada desde la predicción y pronóstico de esta manera logrando una caracterización en estos, (2) los recursos, aspecto que se ha descrito anteriormente en este documento y que para propósitos de esta investigación será estudiado desde la perspectiva de optimización.

La planeación de recursos pretende definir cuántos y cuáles son los recursos necesarios para dar tratamiento a un paciente. Teniendo en consideración los dos elementos mencionados anteriormente, se explican cómo cada uno de estos elementos se componen y se han tratado a lo largo del tiempo. A continuación, se presenta como se ha caracterizado la demanda y qué métodos se han usado para optimizar los recursos.

5.1.1. Caracterización de la demanda de pacientes

Teniendo en consideración lo descrito anteriormente, la caracterización de pacientes desde la perspectiva de estimación y clasificación es crucial para intentar mitigar el sesgo entre lo predicho y lo observado; por ello resulta necesario estimar la cantidad de pacientes que ingresan al sistema y agruparlos en función de características que estos puedan presentar. A partir de lo dicho, definir la cantidad de pacientes que ingresan a un sistema se entiende como el pronóstico, mientras que definir la categoría, clasificación y agrupación de pacientes en función de sus características se asocia a la predicción, en ese orden de ideas, en esta sección se presentan algoritmos implementados en la literatura tanto para el pronóstico, como para la predicción de pacientes.

5.1.1.1. Pronóstico de pacientes

Según la información con la que se cuenta es posible usar métodos que presentan mejor rendimiento con una variable o aquellos que consideran diferentes variables al momento de predecir la cantidad de pacientes que ingresarán al sistema. La **Tabla 3** muestra un resumen de las investigaciones encontradas que se enfocan en la llegada de pacientes a centros de salud.

Tabla 3.
Métodos para pronosticar demanda

Autor	Método							
	AR	NN	SVR	RF	GBM	HM	HW	MLR
Sun et al., (2009)	X							
Abraham et al., (2009)	X							
J. Luo, (2014)						X	X	X
L. Luo et al., (2017)	X			X				
Gul & Celik, (2020)			X				X	X
Mekhaldi et al., (2021)			X	X	X			X
McRae, (2021)	X							
Etu et al., (2022)	X						X	
Mizan & Taghipour, (2022)			X	X				
Tello et al., (2022)			X					
Johnson et al., (2023)	X	X						
Conteo	7	1	4	3	1	1	3	3

ARIMA (AR), Neuronal Network (NN), Support Vector Regression (SVR), Decision Tree (DT), Gradient Boosting Method (GBM), Holt-Winterss (HW), Multiple Linear Regression (MLR), Huff Method (HM)

En la **Tabla 3** se puede observar que para el pronóstico de pacientes se han usado modelos estadísticos y de aprendizaje automático, destacando los modelos ARIMA al momento de ser los más usados, esto debido a que es posible identificar tendencias relacionadas con el comportamiento de los pacientes a lo largo del tiempo; no obstante, en los últimos 10 años los modelos de aprendizaje automático han tomado más fuerza al punto de implementarse cada vez más, esto se debe a que estos no consideran supuestos estadísticos al momento de pronosticar demanda.

5.1.1.2. Predicción de pacientes

Como se mencionó anteriormente parte esencial para la planeación de recursos consiste en la caracterización de los pacientes desde la unión de estos en función de sus atributos; de esta manera facilita la identificación de los recursos asociados a su tratamiento. Sun et al., (2009) agrupa a los pacientes en función de su nivel de agudeza y posteriormente pronostica el número de pacientes. Taboada et al., (2013) separa a los pacientes por zonas y de esa manera dar tratamiento a los pacientes. Además de lo mencionado, Xu et al., (2014) plantea el supuesto de que existen similitudes en pacientes y los recursos que estos pueden requerir, lo cual refuerza el hecho de que al momento de agrupar pacientes el sistema, en este caso los EDs se ven impactados de manera positiva en cuanto a la gestión de los recursos.

Partiendo de lo anterior, los pacientes dentro de los EDs cuentan con diferentes codificaciones en función de colores, los cuales cambian dependiendo la metodología de clasificación usada en los EDs. Kim et al. (2014) y Munavalli et al. (2017) estudian la posibilidad de predecir el ingreso de un paciente a un ED en función de su nivel de triage; sin embargo, la clasificación de triage por sí sola no es suficiente para definir el estado de un paciente, es necesario considerar la incidencia de variables demográficas que ayudan a mejorar la precisión al momento de clasificarlos (Zaerpour et al., 2020). La **Tabla 4** muestra algunos de los algoritmos más usados al momento de agrupar pacientes.

Tabla 4.
Métodos para predecir demanda

Autor	Método						
	<i>K-M</i>	<i>NN</i>	<i>SVM</i>	<i>LR</i>	<i>DT</i>	<i>RF</i>	<i>GBM</i>
Peck et al., (2013)				X			
Xu et al., (2014)	X						
Graham et al., (2018)				X	X		
Jiang et al., (2018)		X	X				
Rawat & Sultana, (2021)					X		X
Tello et al., (2022)	X		X				
Jaotombo et al., (2023)		X		X	X	X	X
Conteo	2	2	2	3	3	1	2

K-Means (K-M), Neuronal Network (NN), Support Vector Machine (SVM), Logistic Regression (LR), Decision Tree (DT), Random Forest (RF), Gradient Boosting Method (GBM)

El rendimiento de cada uno de estos algoritmos varía en función de las características que son identificadas para la posterior ejecución de los métodos, indicando que la selección de variables influye en la predicción de un paciente; por ello, diversos autores hacen uso de algoritmos externos para la selección de características; Jiang et al., (2018) hacen uso de algoritmos genéticos para definir los mejores atributos y posteriormente aplicarle algoritmos de clasificación.

La caracterización de pacientes resulta indispensable puesto que es insumo para conocer el riesgo en el que se encuentra cada uno y que, a partir de la extracción de sintomatologías, definir los recursos asociados a los tratamientos necesarios (Mathauer & Wittenbecher, 2013).

5.1.2. Optimización de recursos

Para la planeación y asignación de recursos en EDs, desde la perspectiva de investigación de operaciones se han presentado diferentes medidas (*Tabla 2*) que ayudan a entender la perspectiva desde la cual puede ser atacado el problema. Considerando el enfoque de optimización, se conocen dos formas que ayudan a la toma de decisiones en los EDs en función de la configuración del sistema, (1) los modelos de simulación y (2) los modelos matemáticos.

5.1.2.1. Modelos de simulación

Los modelos de simulación resultan un recurso útil al momento de observar el comportamiento de un sistema bajo parámetros claramente definidos; esto no solo permite representar la interacción en sistemas reales, sino también definir los recursos con los que el sistema funcionaría de forma eficiente. En la **Tabla 5** se presentan algunas de las técnicas de simulación más implementadas en los EDs.

Tabla 5.
Técnicas de Simulación

Técnica	Descripción	Abreviación
Simulación de eventos discretos	Son modelos en los que los eventos ocurren en un instante del tiempo de ejecución.	DES
Sistemas Dinámicos	Son modelos en los que los eventos ocurren a lo largo del tiempo, indicando el cambio de variables como consecuencia de eventos pasados.	SD
Simulación basada en agentes	Son modelos en el que las acciones de un agente del sistema afectan el comportamiento y rendimiento del sistema en general.	ABS
Discrete Event Simulation (DES), System Dynamic (SD), Agent-Based Simulation (ABS)		
Nota: Adaptado de Taboada et al., (2013)		

Los modelos de simulación resultan útiles puesto que permiten abstraer la realidad y explorar y visualizar diferentes escenarios en función de la interacción de sus parámetros. La **Tabla 6** muestra algunas investigaciones y la métrica de rendimiento que se utilizó, así como la técnica de simulación empleada:

Tabla 6.
Modelos de simulación

Autor	Técnica	Métrica	Descripción
Ahmad et al., (2012)	DES	LOS	El enfoque es observar y definir tiempos de tratamiento, minimizar tiempos de estancia y asignar recursos a pacientes.
Taboada et al., (2013)	ABS	LOS	El enfoque es minimizar el LOS a partir de la interacción de los elementos presentes en el sistema.
Ismail et al., (2014)	DES	LOS	El enfoque es minimizar el LOS y WT, teniendo como consecuencia la maximización de pacientes atendidos.
Sarno & Nenni, (2016)	MCS	WL	Busca examinar la carga laboral del personal desde el estudio de los tiempos de servicio.
Lee et al., (2017)	DES	WT	Minimiza los tiempos de espera en un ED y se consideran dos restricciones que estudian diferentes escenarios.
Yousefi et al., (2018)	ABS	LOS	Minimiza el LOS desde la asignación de recursos e implementado el uso de NN para mejorar el rendimiento.
Zhang et al., (2023)	DES	NB	Busca maximizar la utilización de camas y evaluar el rendimiento del sistema.
Monte Carlo Simulation (MCS)			

Como se evidencia en la **Tabla 6** al tratarse de un sistema de servicios, la métrica representativa más estudiada es el tiempo de estancia, enfocando esta variable a la perspectiva de satisfacción del paciente, en donde se busca que la espera del paciente sea lo más corta posible. Los modelos presentados anteriormente no todos se enfocan exclusivamente en un ED, pero aquellos que no lo hacen, llegan a permear de alguna manera los EDs bajo el concepto de centralización presentado anteriormente. La simulación dentro del tópico tratado permite definir cuántos y qué tipo de recursos son necesarios para lograr que la estancia de pacientes sea más corta.

5.1.2.2. Modelos matemáticos

Los modelos matemáticos dentro de los EDs permiten representar el sistema desde la perspectiva de ecuaciones matemáticas en donde existe solución única, la cual se encuentra sujeta a restricciones que limitan que las variables o medidas involucradas crezcan de manera libre. La

Tabla 7 muestra los tipos de modelo más frecuentes en EDs y demás departamentos involucrados en un sistema de salud.

Tabla 7.
Tipo de programación matemática

Tipo de programación	Descripción	Abreviación
Programación Lineal	Modelos en el que las variables involucradas son estrictamente de primer grado, tanto en su función objetivo, como en sus restricciones.	LP
Programación Lineal Entera Mixta	Modelos en el que la naturaleza de sus variables de carácter discreto y continuo, mantienen las condiciones de LP.	MILP
Programación no Lineal	El máximo grado de las variables es diferente de uno. Se puede presentar interacción entre dos variables lineales	NLP
Programación Entera Mixta	A diferencia de los modelos MILP, en estos no se garantiza la linealidad del modelo.	MIP
Programación Estocástica	La naturaleza del modelo es probabilística, explorando y considerando la ocurrencia de todos los posibles escenarios.	SP
Linear Programming (LP), Mixed-Integer Linear Programming (MILP), Nonlinear Programming (NLP) Stochastic Programming (SP)		

Partiendo de la **Tabla 7**, estos no son los únicos tipos de modelos, puesto que puede existir la mezcla de uno o más tipos de programación. A partir de los tipos de modelo la **Tabla 8** muestra algunos modelos de programación matemática encontrados junto con la métrica que intentan optimizar; estos aplican tanto para EDs como para cualquier otro departamento de un sistema de salud.

Tabla 8.
Modelos de programación matemática

Autor	Program.	Métrica	Descripción
Gallivan & Utley, (2005)	SP	NB	Busca definir el número de camas y estudiar la variación a lo largo del horizonte de planeación.
Harzi et al., (2017)	MILP	WT	Minimiza el tiempo de espera de los pacientes.
Chen & Wang, (2016)	SP	MO	Multiobjetivo: (1) Minimiza el tiempo de espera de cada paciente, (2) Minimiza el desperdicio de recursos.
Daldoul et al., (2018)	SP	WT	Minimiza el tiempo de espera de cada paciente. Los tiempos de espera se estudian desde un sistema de colas.
Moosavi & Ebrahimnejad, (2018)	NLP	MO	Multiobjetivo: (1) minimiza el número de pacientes aplazados para cirugía, (2) Minimiza el costo de espera de pacientes programados y costo de adquirir camas extras, (3) Minimiza la inactividad de quirófanos y las horas extras.
Andersen et al., (2019)	LP	WL	Mínimiza la cantidad de personal asignado a un turno o patrón de turnos.
Güler & Geçici, (2020)	MILP	WL	Realiza la programación de horarios en tiempos pandémicos dentro de EDs.
Tohidi et al., (2021)	NLP	WL	Mínimiza el costo de asignación de personal, considera el costo asociado a rechazo de pacientes.
Mizan & Taghipour, (2022)	MILP	MO	Multiobjetivo: (1) Minimiza el tiempo de espera total, (2) Minimiza el retraso del servicio en centro de procesamiento de imágenes, (3) Reduce la tasa de abandono por no atención, (4) Maximiza el porcentaje de servicio, (5) Minimiza la carga de trabajo.
Ghannam & Othman, (2023)	MIP	WT	Minimiza el tiempo de espera de pacientes en tiempo pandémico y considera más de un ED.
Hu et al., (2023)	MILP	MO	Multiobjetivo: (1) Maximiza la tasa de pacientes atendidos, (2) Minimiza la distancia de desplazamiento de ambulancias.
Fattahi et al., (2023)	SP	WT	Mínimiza la cantidad de pacientes no aceptados, minimizando la cantidad de recursos asignados directamente.

Number beds (NB), Waiting Time (WT), Work Load (WL), Multi-Objective model (MO)

Los modelos matemáticos resultan tener un enfoque más versátil en comparación con los modelos de simulación al considerar múltiples objetivos de manera simultánea, no obstante, surgen otras apuestas en la que se plantea una unión al considerar técnicas de simulación y modelos de programación para dar más rigurosidad y precisión a los modelos propuestos, estos reciben el nombre de Simulación-Optimización (S-O por sus siglas en inglés correspondientes a Simulation-Optimization) que es el resultado de combinar técnicas de simulación para estimar parámetros que

posteriormente serán usados en un modelos matemático. Aboueljinane & Frichi, (2022) hacen uso de S-O para estimar los parámetros tales como tiempos de servicio y la manera en la que llegan los pacientes, lo que posteriormente se usó en el modelo matemático que plantean; estos sugieren que el uso de este método permitió ser más preciso al momento de representar un ED.

5.2. Discusión de la revisión

Para la correcta planeación y asignación de recursos en EDs, resulta necesario tener presente aspectos como la caracterización de pacientes desde la perspectiva de su categoría vista como nivel de gravedad, esto facilita la agrupación desde la similitud en sus síntomas, y es posible abarcarlo desde modelos de aprendizaje automático o los expuestos en la **Tabla 4**. Por otra parte, resulta útil estimar (**Tabla 3**) la cantidad de pacientes que ingresarán al sistema luego de agruparlos, de esa forma llegar a definir la cantidad de recurso necesario en un periodo de tiempo; para lograr esto un método puede ser mejor que otro dependiendo de la información con la que se cuente. En algunos casos los modelos y métodos estadísticos resultan ser mejor opción que los modelos de aprendizaje automático, pero esto es producto de la naturaleza de la información, como ejemplo, los modelos ARIMA, que presentan un mayor rendimiento cuando solo se cuenta con la frecuencia de llegada de los pacientes (L. Luo, Luo, et al., 2017); sin embargo, caracterizar los datos para poder simularlos puede ser otra alternativa implementada, pero cuando se involucran más variables (sexo, edad, etc.) los modelos de aprendizaje automático resultan ser más robustos. Esta caracterización es crucial al momento de considerar un comportamiento de pacientes en EDs puesto que permite integrar un panorama aleatorio como lo es la llegada de pacientes.

Los modelos de simulación y modelos matemáticos presentados en su mayoría, no son exclusivamente para EDs, en algunos casos se consideran la planeación y asignación de recursos en servicios (quirófanos, despliegue de ambulancias, etc.) que no comprenden todo el panorama

de un ED; sin embargo, este enfoque está alejado de la realidad puesto que es necesario descentralizar los EDs para la caracterización de pacientes, pero, considerar su centralización al momento de tomar decisiones, es decir como las decisiones del ED impactan los recursos a nivel general en un sistema de salud.

Hasta donde se conoce son pocos los trabajos que adoptan el enfoque de simulación y optimización centrados en los EDs, lo que sugiere que existe campo para explorar en este aspecto; por otro lado, los modelos que consideran más de una medida de desempeño en un mismo objetivo son limitados (hasta donde se conoce), esto sugiere un aspecto en el cual trabajar y de esa manera impactar en ellas. Los modelos de optimización deterministas encontrados para EDs no consideran directamente el nivel de gravedad de los pacientes (Triage), encontrando solo un trabajo que lo considera de manera parcial (Harzi et al., 2017), esto se debe a que, al tratarse de un sistema real, contemplar todo en un modelo determinista resulta complejo. Por otra parte Aboueljinane & Frichi, (2022) sugieren la articulación de un modelo con dos niveles de decisión, para de esta manera considerar un panorama más amplio y menos limitado en cuanto a las decisiones que se pueden llegar a tomar en un ED.

6. Marco de referencia

La siguiente sección contempla aquellos teorías, conceptos y normativas que se consideran necesarios para el desarrollo del presente trabajo de investigación.

6.1.Marco teórico

6.1.1. *Modelo Optimización-Simulación*

Los modelos de Optimización-Simulación buscan optimizar un sistema representado de forma matemática y posteriormente se evalúa su desempeño empleando simulación para explorar su comportamiento en diferentes escenarios con el fin de tomar decisiones asociadas que se asemejan a la realidad (Amaran et al., 2016).

6.1.2. *Planeación de recursos sanitarios*

La planeación de recursos sanitarios se presenta como un conjunto de métodos de trabajo aplicados a cualquier campo (López De Castro & Alcalá, 2003). Dicho de otra forma, se define como la gestión de actividades o recursos involucrados en un sistema de salud.

6.1.3. *Triage*

Se entiende como triage a un sistema de selección y clasificación de pacientes, basado en las necesidades con el fin de determinar la prioridad con la que un paciente será atendido (Resolución 5596 de 2015- Art. 3).

6.1.4. *Ruta clínica*

La ruta clínica es una herramienta que se usa para guiar la atención médica de un paciente basado en las sintomatologías que presenta que tiene como objetivo mostrar los procesos clínicos a los cuales se va a someter un paciente (Rotter et al., 2019).

6.2.Marco conceptual

6.2.1. *Análisis de criticidad*

Se entiende por el análisis de criticidad como el estudio del nivel de gravedad que presentan un paciente, entre ello corresponde el comportamiento de los tiempos de llegada y la ruta clínica asociada a cada paciente en función de su nivel de triage.

6.2.2. *Requerimiento de tratamientos*

Hace referencia a los recursos que serán usados por un paciente en función de la ruta clínica asignada y procedimiento médico llevado a cabo, los cuales corresponden al nivel de triage asignado para dicho paciente.

6.3.Marco legal

6.3.1. *Ley 100 de 1993*

Se establece que toda persona debe estar asociada afiliada al sistema de salud (Art. 153), por consiguiente, establece que toda persona debe ser atendida en un centro de salud, sin importar su condición.

6.3.2. *Resolución 3100 de 2019*

Se establecen los procedimientos y estándares mínimos de los sistemas prestadores de salud en Colombia en función de la clasificación que estos obtienen.


6.3.3. *Resolución 5596 de 2015*

Se establecen y definen los criterios técnicos para el sistema de y clasificación de pacientes en los servicios de urgencias (Triage).

7. Análisis y caracterización del sistema

Para esta sección se recurre a la búsqueda de datos en bases de datos abiertas, obtenidos de una fuente gubernamental colombiana (Clasificación En Triage Urgencias | Datos Abiertos Colombia) y son proporcionada por “Empresa Social del Estado Pasto Salud E.S.E”; dicha base cuenta con 24.342 registros asociados al centro de salud SAN VICENTE en la zona de urgencias (ED); cada registro describe la información relacionada al nivel de triage del paciente, la hora de llegada y hora de atención. Siguiendo la serie de pasos establecidos en la **Figura 2**, el primero de ellos hace referencia a la limpieza de datos, esto implica la depuración y limpieza de información, identificar aquellos datos atípicos que producen ruido y entorpecen el análisis posterior.

Una vez verificados los datos en los formatos de hora y fecha correctos, es posible extraer la información asociada al tiempo entre llegadas por paciente en cada nivel de triage; esto servirá posteriormente como parámetro de entrada para el modelo de optimización el cual permitirá definir el momento de llegada de un paciente; el tratamiento de datos se realizó por medio del software Python en su versión 3.11. La **Figura 6** muestra el diagrama de dispersión que permite visualizar el tiempo entre llegadas en minutos asociado a cada uno de los niveles de triage (5 niveles) de todos los pacientes presentes en la base, en este es posible observar datos que producen ruido al momento de intentar analizarse, el comportamiento extraño en los datos es producto de datos faltantes, puesto que los datos inician el primero de enero de 2020 y presentan un corte en marzo 30 del mismo año y no hay existencia de datos hasta 01 de abril de 2021, esta fragmentación en la información se presume que es producto de la pandemia asociada a COVID-19. Por esta razón, se decide eliminar los datos que se escapan de la nube de datos.

Figura 6.*Dispersión, tiempo entre llegadas*

A partir de la información suministrada en la base de datos, se realiza un análisis posterior para identificar el tiempo que transcurrió a la primera visita del médico, el cual sería la suma de tiempo de registro más el tiempo de clasificación en triage. Una vez se obtuvieron estos valores se encontraron algunos valores en negativo indicando que el tiempo en el que se les prestó atención era antes de su hora de llegada, esto sugiere que los datos fueron registrados de manera incorrecta, por esta razón se procede a eliminarlos.

Considerando lo anterior y con el fin de intentar caracterizar el tiempo desde el ingreso del paciente hasta la primera visita del médico, se realiza una prueba bondad de ajuste para determinar si los tiempos sumados siguen alguna distribución estadística teórica conocida aplicando la prueba Kolmogorv-Smirnov (K-S) con un nivel de confianza del 95%. Debido a que los datos presentan un alto volumen de información y al considerarse todos los datos se puede ocultar información importante, se procede a extraer una muestra y hacer inferencia estadística a partir de la misma. La fórmula aplicada para la extracción de la muestra bajo la consideración de una población infinita cuya desviación estándar es de aproximadamente 32.36 minutos, dando un total de 478

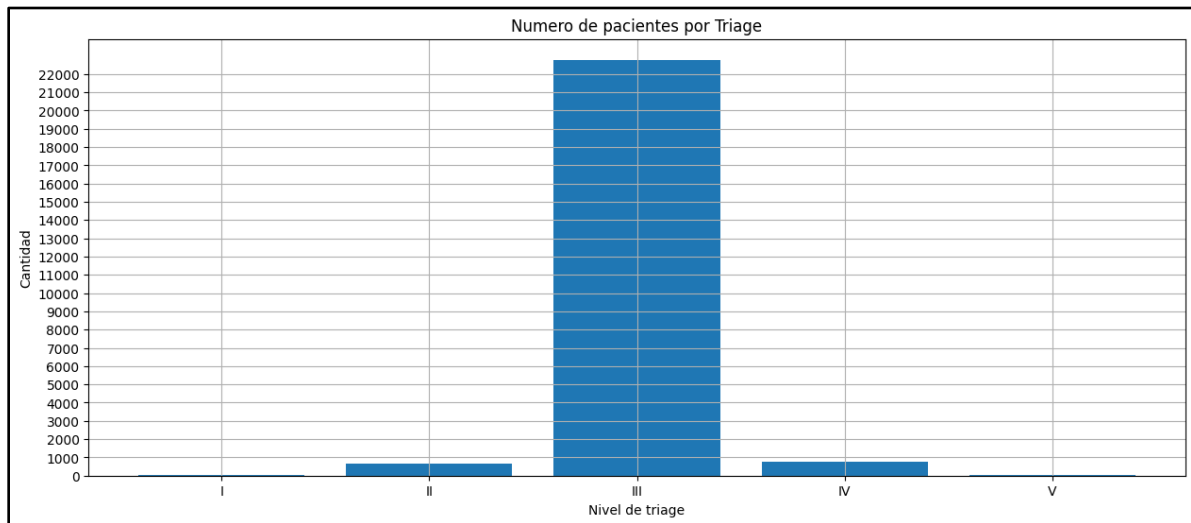
muestras. La prueba bondad de ajuste para el tiempo transcurrido al primer tratamiento se muestra en la **Tabla 9**.

Tabla 9.
Bondad de ajuste, tiempo de registro y clasificación

Distribución	K-S	P-valor
Triangular	0.3627	7.46e-57
Normal	0.1630	1.42e-11
Logística	0.1586	5.57e-11
Cauchy	0.1869	4.27e-15
Exponencial	0.0326	0.6743
Lognormal	0.0352	0.5786
Gamma	0.0385	0.4642
Weibull	0.0367	0
Uniforme	0.5373	1.37e-129

A partir de lo encontrado, el tiempo de servicio asociado a registro y clasificación, es posible modelarlo por medio de una distribución exponencial con una tasa de servicio aproximada de 0.033 pacientes por minuto, esto análisis es válido únicamente para el ED tratado.

Observando detalladamente la **Figura 6**, se procede a visualizar como se encuentra compuesto cada uno de los niveles de triage en función de la cantidad de pacientes asociado a cada uno de ellos. La **Figura 7** muestra la forma en la que está compuesta cada clase en función de la frecuencia presente, la cual según el volumen de datos se componen como: para los niveles I, II, III, IV y V en función de la base cuenta con 0.1280%, 2.6760%, 94.0532%, 3.0560% y 0.0868% respectivamente.

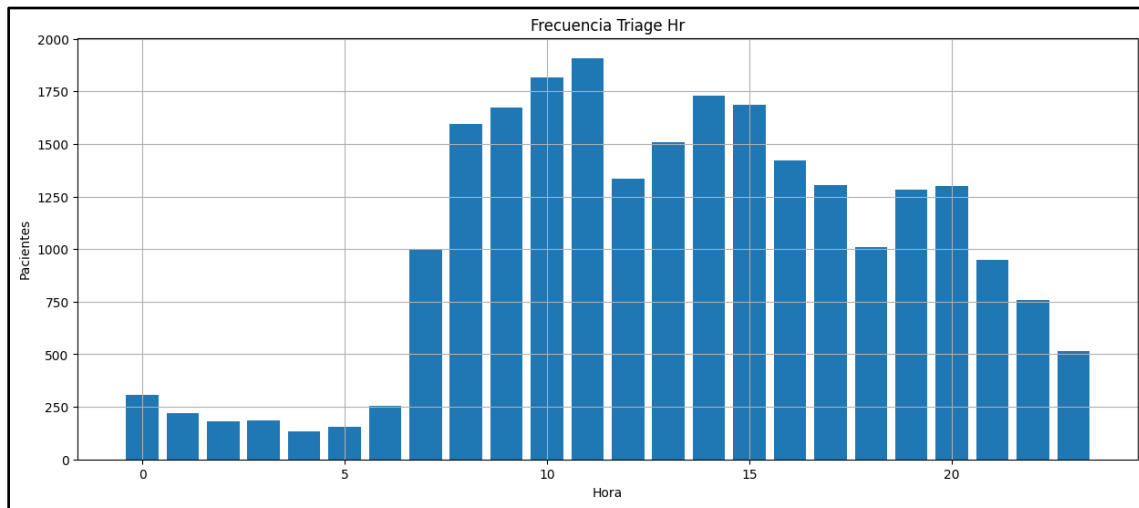
Figura 7.*Frecuencia de pacientes por nivel de triage*

Resulta necesario resaltar que si se desea clasificar los pacientes en función de sus características se presentaría un problema de balanceo de clases, para ello resulta necesario equilibrar las clases antes de poder usar una máquina que clasifique los pacientes en función de sus características.

A partir de los datos se busca observar el comportamiento de los pacientes sin tener en cuenta su nivel de triage a lo largo de las horas del día; este análisis resultante permite identificar en qué momento del día se deben concentrar los esfuerzos. La **Figura 8** presenta el número de pacientes en cada hora del día.

Figura 8.

Frecuencia de pacientes por hora del día.



El comportamiento observado resulta ser similar al presente en otros ED encontrados en literatura, sugiriendo que la mayor afluencia de pacientes en departamentos de emergencia se da en horas del día. De esta forma la programación de personal debería tener en cuenta este comportamiento en la franja horaria de 7 am a 8 pm (Daldoul et al., 2018; Lee et al., 2017; Yousefi et al., 2018).

Debido al alcance de la información, los datos recolectados solo permiten realizar la etapa de pronóstico para cada nivel de triage, los cuales son estudiados por separado. Antes de recurrir a modelos de aprendizaje automático, se realiza la prueba bondad de ajuste para determinar si los datos siguen alguna distribución estadística teórica conocida, esto con el fin de poder modelar el tiempo entre llegada de los pacientes en cada uno de los niveles de triage. La **Tabla 10** muestra la prueba bondad de ajuste aplicada a cada nivel de triage y su ajuste por medio de la prueba K-S.

Tabla 10.*Bondad de ajuste, tiempo entre llegadas*


Triage	Estad.	Trian	Norm	Logis	Cauch	Expon	LogNo	Gam	Weib	t	Unif
I	K-S	0.2328	0.1705	0.1681	0.2105	0.0863	0.0794	0.3858	0.2863	0.1753	0.4477
	P-valor	0.0726	0.3297	0.3460	0.1318	0.9691	0.9861	2.1e-4	0.0139	0.2988	8e-6
II	K-S	0.4152	0.2170	0.2189	0.2757	0.1761	0.1084	0.0478	0.0612	0.2365	-
	P-Valor	6e-102	3e-27	1e-27	3e-44	5e-18	4.5e-7	0.1009	0.0150	2e-32	-
III*	K-S	0.5815	0.2366	0.2136	0.2378	0.1299	0.0459	0.6826	0.0689	0.2206	0.7177
	P-Valor	5e-154	4e-24	1e-19	2e-24	1.6e-7	0.2571	1e-221	0.0202	6e-21	0
IV	K-S	0.4074	0.2323	0.2445	0.3309	0.2771	0.1363	0.1099	0.1691	0.3452	-
	P-Valor	2e-110	3e-35	4e-39	5e-72	3e-50	2e-12	3.6e-8	9e-19	2e-78	-
V	K-S	0.2072	0.1716	0.1553	0.2121	0.1381	0.4053	0.2321	0.1170	0.1622	0.3895
	P-Valor	0.3705	0.6043	0.7213	0.3428	0.8368	3e-3	0.2455	0.9418	0.6721	5e-3

Nota: el símbolo * indica que se encuentra sujeto a la muestra

Distribución Triangular (Trian), Distribución Normal (Norm), Distribución Logística (Logis), Distribución Cauchy (Cauch), Distribución Exponencial (Expon), Distribución LogNormal (LogNo), Distribución Gamma (Gam), Distribución Weibull (Weib), Distribución t (t), Distribución Uniforme (Unif)

A partir de la **Tabla 10** se observa que para estos datos, el tiempo entre llegadas para los niveles II y V se pueden modelar como una distribución Gamma y Weibull respectivamente, para el nivel I, si bien la distribución que más se ajusta es la distribución Lognormal, esta se ajusta con parámetros negativos y genera valores negativos, que desde un punto de vista práctico no tiene sentido, por ello el nivel I se modela como la siguiente distribución que mejor se ajusta, una distribución exponencial. El nivel III debido a que compone más del 90% de los datos, y por las razones mencionadas al momento de caracterizar el tiempo de registro y triage, a este nivel se le aplica la misma metodología, en donde se extrae una muestra representativa para caracterizarlo. Se corrió 50 veces la una muestra aleatoria y el resultado en todos los casos indicaba que es posible modelar los datos como una distribución Lognormal. El nivel IV se evidencia que no se ajusta a ninguna distribución conocida, por ello se recurre a graficar en diagramas de frecuencias y dispersión el nivel IV para identificar a detalle que ocurre. La **Figura 9** describe lo mencionado anteriormente con el nivel IV.

Figura 9.
Triage IV



Apoyado en la **Figura 9** se observa que la gráfica de frecuencias presenta dos picos, indicando que se puede tratar de una distribución mezclada, para ello se traza un corte en los datos, el corte está apoyado en la gráfica de dispersión de un solo eje, esto para identificar que posibles comportamientos de variables pueden construir la distribución descrita, la cual se describe en la **Figura 10**.

Figura 10.
Distribución mezclada

$$F(x) = \beta_1 * f_1(x) + \beta_2 * f_2(x)$$

$$f_1(x) = \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{(x-\mu_1)^2}{2\sigma_1^2}\right)$$

$$f_2(x) = \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left(-\frac{(x-\mu_2)^2}{2\sigma_2^2}\right)$$

La distribución mezclada tiene la particularidad que $\beta_1 + \beta_2 = 1$ esto es para dos distribuciones. A partir de la sospecha que la distribución mezclada puede estar compuesta por dos distribuciones Lognormal como se muestra en las ecuaciones (2) y (3), se emplea el algoritmo E-M (por sus siglas en inglés correspondientes a Expectation-Maximization) para estimar los pesos respectivos y los parámetros asociados a cada distribución de probabilidad. La **Tabla II** resume los parámetros asociados a la distribución mezclada.

Tabla 11.
Parámetros distribución mezclada

	β	μ	σ
f_1	0.45480953	7.461153415120138	0.6843174633685857
f_2	0.54519047	4.258943240426665	1.4157530651304484

A partir de estos parámetros se realiza una prueba bondad de ajuste para determinar si los datos se ajustan a una distribución mezclada bajo los parámetros hallados en la **Tabla II**. La prueba bondad de ajuste nos arroja un estadístico K-S de 0.036787256 y un P-valor de 0.284644 indicando que no existe evidencia significativa para sugerir que los datos provienen de una distribución diferente. Esta caracterización de triage se realizó para definir el comportamiento de cada uno de los niveles de criticidad, aspecto que posteriormente será de gran ayuda para la simulación de llegada de pacientes. Además de considerar cada nivel de triage, se caracteriza la llegada en general de pacientes al ED, esto con el fin de implementar este elemento como la llegada de pacientes que posteriormente será usado en la fase experimental del modelo de optimización.

Otro elemento importante además de la caracterización de pacientes en función del tiempo de llegada para cada nivel de gravedad es la identificación de la ruta clínica en un ED asociada a cada nivel emergencia. En los ED los pacientes presentan 4 diferentes formas de ingreso, (1) ingreso por ambulancia, (2) por ingreso voluntario, (3) provenientes de otro centro asistencial y

(4) provenientes de un departamento interno del centro asistencial (Cheng et al., 2016), seguido a su ingreso cada paciente realiza un registro y clasificación, luego de esto toma una ruta específica para recibir tratamiento, siendo el nivel I el paciente más crítico y el nivel V el menos urgente; la clasificación del nivel cambia en función del sistema de triage que emplee cada centro asistencial. Luego de la clasificación cada paciente hace uso de un recurso diferente en una ruta diferente. El diagrama de flujo del ED se construye tomando como base el diagrama planteado por Keshtkar et al., (2015), posterior a ello y considerando que se pretende plantear un diagrama de flujo que no contenga características específicas en cuanto a su ruta de ningún ED, el diagrama de Keshtkar et al., (2015) se modifica considerando partes aspectos de Lee et al., (2017), Daldoul et al., (2018) y Yousefi et al., (2018); el diagrama de flujo construido, junto con los parámetros de servicio asociado a cada uno de ellos se presenta en el *Anexo D*, este describe el diagrama de flujo de un ED bajo la construcción de los autores mencionados anteriormente y validado con personal de urgencias. Este diagrama sirve para identificar la posible ruta asociada a cada nivel de triage y los recursos que se relacionan a cada a cada tipo de paciente clasificado en los niveles de gravedad (Triage). Las rutas asociadas a cada nivel de triage se muestran en el *Anexo D*. Para el sistema en cuestión se identifican un total de 12 actividades mostradas en la **Tabla 12**.

Tabla 12.
Actividades del sistema

Actividad	Descripción
Registro y triage	Etapa de admisión de pacientes y clasificación de ellos (asignación de nivel de triage).
Reanimación cardio cerebro pulmonar (CPR)	Etapa de reanimación de pacientes.
Emergencia de riesgo vital (SAUV)	Etapa de emergencia que puede poner en riesgo la vida del paciente.
Médico general	Etapa de primera visita a médico general quien establece el tratamiento que se va a realizar para cada paciente.
Tratamiento 1	Etapa donde se da tratamiento a los pacientes nivel 5
Exámenes básicos	Etapa de definición de toma de muestras
Tratamiento 2	Etapa de toma muestras.
Radiología	Etapa de rayos X para pacientes nivel I-II-III y IV
Evaluación Quirúrgica	Etapa donde se define si es necesaria cirugía (cirugía menor)
Cirugía menor	Etapa de suturas, en caso de requerirse otro tipo de cirugía se designa al área encargada.
Visita médico general	Etapa de revisión cuando el paciente se encuentra en observación.
Tratamiento 3	Etapa de tratamiento definido luego de la segunda visita del médico.
<i>Cardiopulmonary Resuscitation (CPR), Life-threatening emergency (SAUV)</i>	

La **Tabla 12** muestra las actividades que a manera general se encuentran en un ED, iniciando con el Registro y triage del paciente, luego se tiene la reanimación cardio cerebro pulmonar (CPR) que está designada únicamente para el triage nivel 1, seguido a esta se encuentra SAUV, la cual solo los niveles 1 y 2 hacen uso de ella. Posterior todos los pacientes pasan a una visita de médico general el cual define el tratamiento que se realizará para cada paciente; únicamente los pacientes nivel 5 pasan por el tratamiento 1, en esta etapa se define el plan de acción para dar atención médica. Los pacientes nivel 4 luego de su visita a médico general pasan a realización de exámenes y posteriormente vuelve a medico general para ser dados de alta. Los pacientes nivel 3 a diferencia del nivel 4, pasan por radiología en búsqueda de posibles intervenciones menores. Luego el nivel 1 y 2 no realiza directamente exámenes básicos debido a que su estado es grave y pasan directamente a radiología y continúan con las demás actividades. Para mejor visualización del proceso el **anexo D** muestra el flujo que sigue cada paciente de cada nivel de triage.

La caracterización de los recursos asociados a los requerimientos de los pacientes para los diferentes niveles de gravedad junto con las rutas de tratamiento clínico (*Anexo D*) y los tiempos de servicios para cada proceso de la ruta clínica son caracterizados desde literatura (explicados a detalle en la *sección 8.2*); estos constituyen el insumo para los parámetros de entrada que se utilizarán posteriormente en el desarrollo del modelo de optimización.

8. Formulación de un Modelo Matemático

Esta sección se enfoca en la formulación del modelo de optimización luego de caracterizado el sistema que se pretende representar. Se diseñó un modelo de programación lineal entera mixta (MILP) el cual sigue los siguientes supuestos:

- **S1.** No hay dos pacientes con el mismo momento de llegada. Solo ingresa un paciente a la vez al sistema, lo que indica que incluso si dos pacientes presentan provienen del mismo sitio, uno de ellos ingresará primero y luego el otro.
- **S2.** Todos los pacientes deben ser atendidos y no se considera abandono del sistema. Debido a que en sistemas reales si un paciente percibe que su espera es muy alta el paciente abandona el sistema, en este caso no se considera abandono del sistema.
- **S3.** Los tiempos de atención para los pacientes son diferentes y se conocen de antemano. Cada paciente tiene un nivel de triage y por cada actividad se simula un tiempo de atención.
- **S4.** Se conoce de antemano el nivel de gravedad de cada paciente (Triage) y por consiguiente su ruta clínica.
- **S5.** El momento de llegada de cada paciente es conocido. Como complemento del S1, se sabe en qué momento de la jornada ingresará el paciente.
- **S6.** Solo se consideran recursos humanos. Debido a que el flujo del paciente está dado por la disponibilidad del personal médico se considera solamente este como recurso crítico, tendiendo cuatro tipos de recurso.
- **S7.** Los recursos (personal) no sufren de cansancio y no toman.
- **S8.** Todos los pacientes son admitidos.

8.1.Descripción del modelo matemático

Para el desarrollo del modelo matemático se definió:

8.1.1. Conjuntos

- $i \in I \rightarrow i \in \mathbb{Z}^+$. Representa el índice de cada paciente.
- $p \in I \rightarrow p \in \mathbb{Z}^+$. Conjunto auxiliar.
- $j \in J \rightarrow j \in \mathbb{Z}^+$. Representa el índice de la actividad de la ruta clínica.
- $k \in J \rightarrow k \in \mathbb{Z}^+$. Conjunto auxiliar
- $h \in H \rightarrow h \in \mathbb{Z}^+$. Representa el índice de cada tipo de recurso (1=Médico general, 2=Auxiliar enfermería, 3=Enfermera, 4=Especialista).
- $c \in C \rightarrow c \in \mathbb{Z}^+$. Representa el índice del nivel de triage.

8.1.2. Parámetros del modelo

- SC_h . Costo por jornada del tipo de recurso h.
- I_i . Razón de incremento en costo por tiempo de espera de cada paciente i.
- AT_{ij} . Tiempo de atención del paciente i en la actividad j.
- CR_{ij} . Ruta clínica: 1 cuando el paciente i realiza la actividad j, 0 de lo contrario.
- RC_{ijh} . Consumo de recurso: 1 cuando el paciente i en la actividad j necesita el tipo de recurso h.
- MT_{ic} . Tiempo máximo a de espera: tiempo máximo que puede esperar un paciente i de nivel c hasta su primera evaluación para las actividades $j \in \{1,4\}$.
- TA_i . Momento de llegada del paciente i
- CP_{ic} . Clasificación de paciente: 1 cuando el paciente i pertenece a la clase de triage c. 0 en caso contrario.

- M . Número muy grande.

8.1.3. Variables de decisión

Variables Continuas:

- ST_{ij} . Momento de inicio del paciente i en la actividad j .
- ET_{ij} . Momento de fin del paciente i en la actividad j .
- WT_{ij} . Tiempo de espera del paciente i antes de iniciar la actividad j .

Variables Discretas:

- S_h . Numero de recurso de tipo h .

Variables Binarias:

- R_{ijpk} . 1 si el momento de finalización del paciente i en la tarea j es mayor que el momento de inicio del paciente p en la tarea k . 0 en caso contrario
- S_{ijpk} . 1 si el momento de inicio del paciente i en la tarea j es mayor que el momento de inicio del paciente p en la tarea k . 0 en caso contrario
- U_{ijpk} . 1 si el momento de finalización del paciente i en la tarea j es mayor que el momento de finalización del paciente p en la tarea k . 0 en caso contrario
- W_{ijpk} . 1 si el momento de inicio del paciente i en la tarea j es mayor que el momento de finalización del paciente p en la tarea k . 0 en caso contrario
- B_{ijpk} . Variable auxiliar para discretizar a evento: 1 si el paciente p en la actividad k inicia y termina su actividad sobre la actividad j del paciente i . 0 en caso contrario.
- T_{ijpk} . Variable auxiliar que guarda una operación.

- Q_{ijpkh} . Variable auxiliar para consumo de recurso. 1 si el paciente i en la actividad j está usando el recurso h mientras que el paciente p en la actividad k lo solicita. 0 en caso contrario.

8.1.4. Función objetivo

Minimiza el costo de servicio, dado por el costo de personal involucrado y el costo de tiempo de espera por paciente.

$$\min Z = \sum_h SC_h * S_h + \sum_i \left(\sum_h SC_h \right) * I_i * \left(\frac{\sum_j WT_{ij}}{10} \right) \quad (1)$$

8.1.5. Restricciones del modelo

$$ST_{i1} \geq TA_i \quad \forall i \quad (2)$$

$$ST_{ij} \geq ET_{i,j-1} \quad \forall i, \forall j \rightarrow j > 1 \quad (3)$$

$$ET_{ij} = ST_{ij} + AT_{ij} * CR_{ij} \quad \forall i, \forall j \quad (4)$$

$$WT_{i1} = TI_{i1} - TA_i \quad \forall i, \forall j \rightarrow j > 1 \quad (5)$$

$$WT_{ij} \geq TI_{ij} - TF_{i,j-1} \quad \forall i, \forall j \rightarrow j > 1 \quad (6)$$

$$M * R_{ijpk} \geq ET_{ij} - ST_{pk} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (7)$$

$$M * (1 - R_{ijpk}) > ST_{pk} - ET_{ij} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (8)$$

$$M * S_{ijpk} \geq ST_{ij} - ST_{pk} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (9)$$

$$M * (1 - S_{ijpk}) > ST_{pk} - ST_{ij} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (10)$$

$$M * U_{ijpk} \geq ET_{ij} - ET_{pk} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (11)$$

$$M * (1 - U_{ijpk}) > ET_{pk} - ET_{ij} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (12)$$

$$M * W_{ijpk} \geq ST_{ij} - ET_{pk} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (13)$$

$$M * (1 - W_{ijpk}) > ET_{pk} - ST_{ij} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (14)$$

$$2 * B_{ijpk} \geq (R_{ijpk} - S_{ijpk}) + (U_{ijpk} - W_{ijpk}) - 1 \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (15)$$

$$2 * (1 - B_{ijpk}) \geq 1 - ((R_{ijpk} - S_{ijpk}) + (U_{ijpk} - W_{ijpk})) \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (16)$$

$$TI_{ijpk} = (R_{ijpk} - S_{ijpk}) + (U_{ijpk} - W_{ijpk}) - B_{ijpk} \quad \forall i, \forall j, \forall p, \forall k \rightarrow i \neq p \quad (17)$$

$$RC_{ijh} + \sum_{p \neq i} \sum_{k > 1} RC_{p,k-1,h} * Q_{ijpk-1h} + RC_{pjh} * T_{ijpj} \leq S_h \quad \forall i, \forall j, \forall h, k > 1 \quad (18)$$

$$Q_{ijpkh} \geq RC_{pk-1h} * T_{i,j,p,k-1} - \sum_{t=k} RC_{pth} * T_{ijpt} \quad \forall i, \forall j, \forall p, \forall k, \forall h \rightarrow i \neq p, k > 1 \quad (19)$$

$$M * (1 - Q_{ijpkh}) > \left(\sum_{t=k} RC_{pth} * T_{ijpt} \right) - RC_{pk-1h} * T_{i,j,p,k-1} \quad \forall i, \forall j, \forall p, \forall k, \forall h \ i \neq p, k > 1 \quad (20)$$

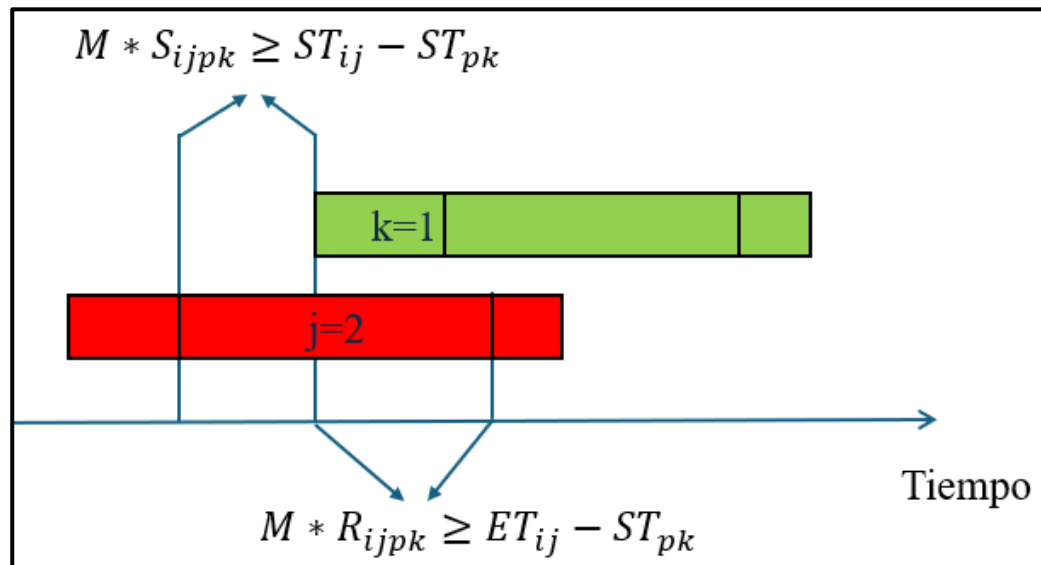
$$CP_{ic} * \sum_{j=1}^4 WT_{ij} \leq MT_{ic} * CP_{ic} \quad \forall i, \forall c \quad (21)$$

$$\sum_j WT_{ij} \leq 240 \quad \forall i \quad (22)$$

La ecuación (1) describe el comportamiento de la función objetivo en donde se pretende minimizar el costo del servicio dado por el costo de personal más un costo de penalización por cada 10 minutos de tiempo de espera (WT_{ij}), obteniéndose así un incremento porcentual (I_i) al costo de atención ($\sum_h SC_h$) en donde se establece que cuanto menor el nivel de triage del paciente, mayor debe ser el incremento (Woodworth & Holmes, 2020). Las restricciones (2) a la (6) describen la secuenciación de tareas para cada paciente. Las restricciones (7) a la (10) discretizan el tiempo en un evento en el que se define si un paciente inicia una actividad con relación a otro paciente, tal como se ilustra en la **Figura II**.

Figura 11.

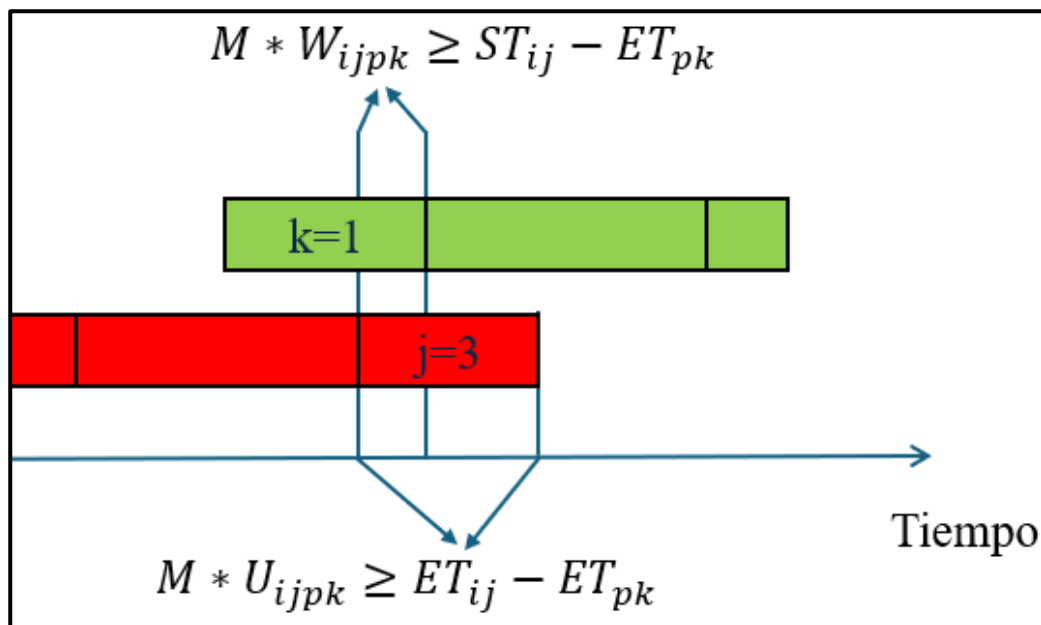
Forma gráfica del funcionamiento de restricciones 7 a 10



Las restricciones (11) a (14) discretizan el tiempo en eventos en el que se define si un paciente termina una actividad con relación a otro paciente, tal como se muestra en la **Figura 12**.

Figura 12.

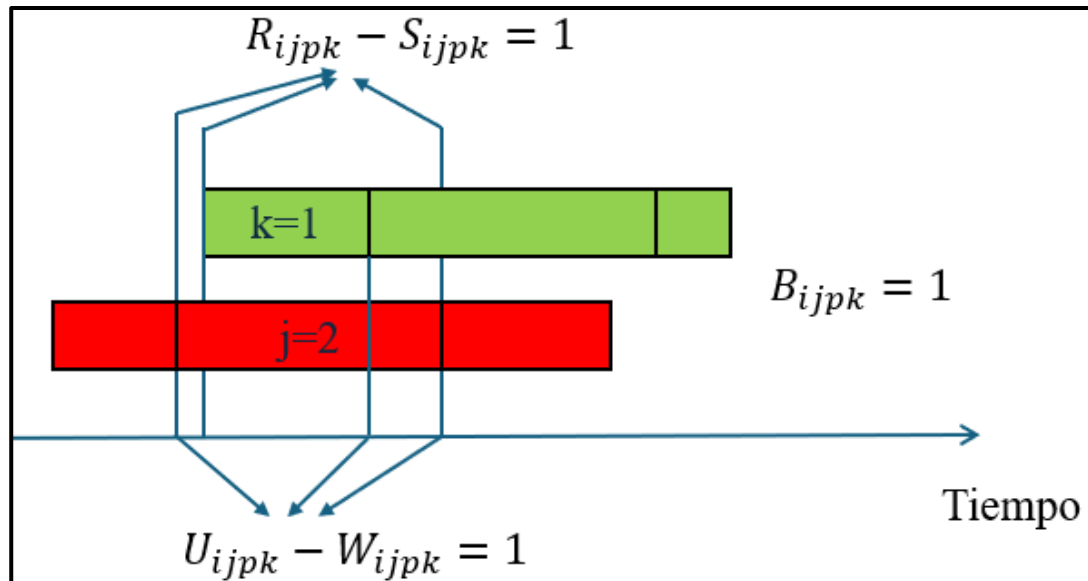
Forma gráfica del funcionamiento de restricciones 11 a 14



Las restricciones (15) y (16) ajustan el modelo a que si un paciente inicia (ST_{ij}) y termina (ET_{ij}) una actividad mientras que se ejecutaba la de otro paciente, su presencia no sea el doble, sino solamente una vez. La **Figura 13** muestra lo descrito anteriormente.

Figura 13.

Forma gráfica del funcionamiento de restricciones 15 y 16



La restricción (17) almacena el resultado obtenido para comodidad en la manipulación de la respuesta. La restricción (18) se encarga de hacer que en un momento en el tiempo no se supere cierto número de recursos (S_h). Las restricciones (19) y (20) garantizan que un paciente use el mismo recurso que liberó si eso disminuye los tiempos de espera. La restricción (21) se encarga de establecer el tiempo máximo hasta la visita del primer médico (Actividad 4 para cualquier paciente), este tiempo máximo está en función del triage, el cual su tiempo se define por políticas gubernamentales y de cada ED donde se definen tiempos máximos para la clasificación Manchester (Soler et al., 2010). Finalmente, la restricción (22) establece un máximo a la suma total de tiempos de espera en todas las actividades; se establece un tiempo de 240 minutos soportado en la investigación Etu et al., (2022) donde se encuentra que si un paciente

percibe que su tiempo de espera acumulado es superior a las 4 horas el paciente prefiere abandonar el sistema independiente de su estado crítico.

8.2. Obtención de soluciones a partir del modelo

En esta etapa se busca que el modelo efectivamente represente la esencia de lo que se quiere (secuenciación de pacientes y definición del número de recursos), para ello se designa un análisis de escenarios que fue contrastado con la puesta en marcha del modelo matemático. La **Tabla 13** describe las características de la máquina implementada y la versión del software empleado.

Tabla 13.
Características del equipo

Versión del software	Matlab R2024b
	16 GB de memoria RAM
Característica del equipo	Procesador Intel(R) Core™ i5-10300H CPU @ 2.50GHz 2.50GHz
	Sistema de 64 bits

El código asociado a la ejecución del modelo se muestra en al **anexo B**. Para el análisis de escenarios se seleccionan 3 pacientes y se ejecutan las 12 actividades caracterizadas en la **sección 7**. La generación de tiempos de atención es simulada a partir de caracterización realizada en la **sección 5** y validación de rutas de la **sección 6**. La llegada de pacientes es simulada a partir la caracterización de cada nivel de triage, proceso descrito a lo largo de la **sección 6**. La **Tabla 14** describe lo mencionado.

Tabla 14.
Simulación de datos

Parámetro	Simulación	Autor
AT_{ij}	Tiempo de atención	
<i>R&T</i> (TA_{i1})	Uniform (3,5)	(Daldoul et al., 2018)
<i>CPR</i> (TA_{i2})	Expon (30)	(Lee et al., 2017)
<i>SAUV</i> (TA_{i3})	Expon (30)	(Daldoul et al., 2018)
<i>GP</i> (TA_{i4})	Expon (9)	(Daldoul et al., 2018)
<i>T1</i> (TA_{i5})	Expon (30)	(Lee et al., 2017)
<i>BE</i> (TA_{i6})	Expon (10)	(Lee et al., 2017)
<i>T2</i> (TA_{i7})	Expon (30)	(Daldoul et al., 2018)
<i>R</i> (TA_{i8})	Tiang (15,30,45)	(Yousefi et al., 2018)
<i>SA</i> (TA_{i9})	Expon (5)	(Daldoul et al., 2018)
<i>MS</i> (TA_{i10})	Triang (10,15,30)	(Yousefi et al., 2018)
<i>GP</i> (TA_{i11})	Expon (9)	(Daldoul et al., 2018)
<i>T3</i> (TA_{i12})	Expon (15)	(Lee et al., 2017)
TA_i	Momento de llegada	
<i>Triage nivel 1</i>	Expon(21094.04;159.66)*	
<i>Triage nivel 2</i>	Gamma(0.542;2543.79;2.4333)**	
<i>Triage nivel 3</i>	LogNorm(1.31;1.865;15.272)***	
<i>Triage nivel 4*</i>	$B_1 \text{LogNorm}(\mu_1, \sigma_2) + B_2 \text{LorNorm}(\mu_2, \sigma_2)$	
<i>Triage nivel 5</i>	Weibull(0.764; 17909.498;8.083)****	
MT_{ic}	Tiempo máximo de espera hasta la primera visita del médico (TA_{i4})	
<i>Triage 1</i> (MT_{i1})	0 min	(Soler et al., 2010)
<i>Triage 2</i> (MT_{i2})	10 min	(Soler et al., 2010)
<i>Triage 3</i> (MT_{i3})	60 min	(Soler et al., 2010)
<i>Triage 4</i> (MT_{i4})	120 min	(Soler et al., 2010)
<i>Triage 5</i> (MT_{i5})	240 min	(Soler et al., 2010)
Nota: Para la simulación de datos en Python ²		
* Escala(β), desplazamiento(μ)		
** Forma(k), Escala(θ), Desplazamiento(μ)		
*** MediaLog(μ), Desviación(σ), Desplazamiento		
**** Forma(k), Escala(λ), Desplazamiento		
Resgistration and Tieage (R&T), Cardiopulmonary Resuscitation (CPR), General Physician (GP), Treatment 1 (T1), Basic Examination (BE), Treatment 2 (T2), Radiology (R), Surgical Assessment (SA), Minor Surgery (MS), General Physician (GP), Treatment 3 (T3)		

Una vez simulados los parámetros, se lleva a cabo un análisis de escenarios considerando el número de recursos (S_h) como un parámetro y evaluando su impacto de cada posible configuración en los tiempos de espera. De esta manera para la verificación del modelo, se ejecuta

² Software de código abierto.

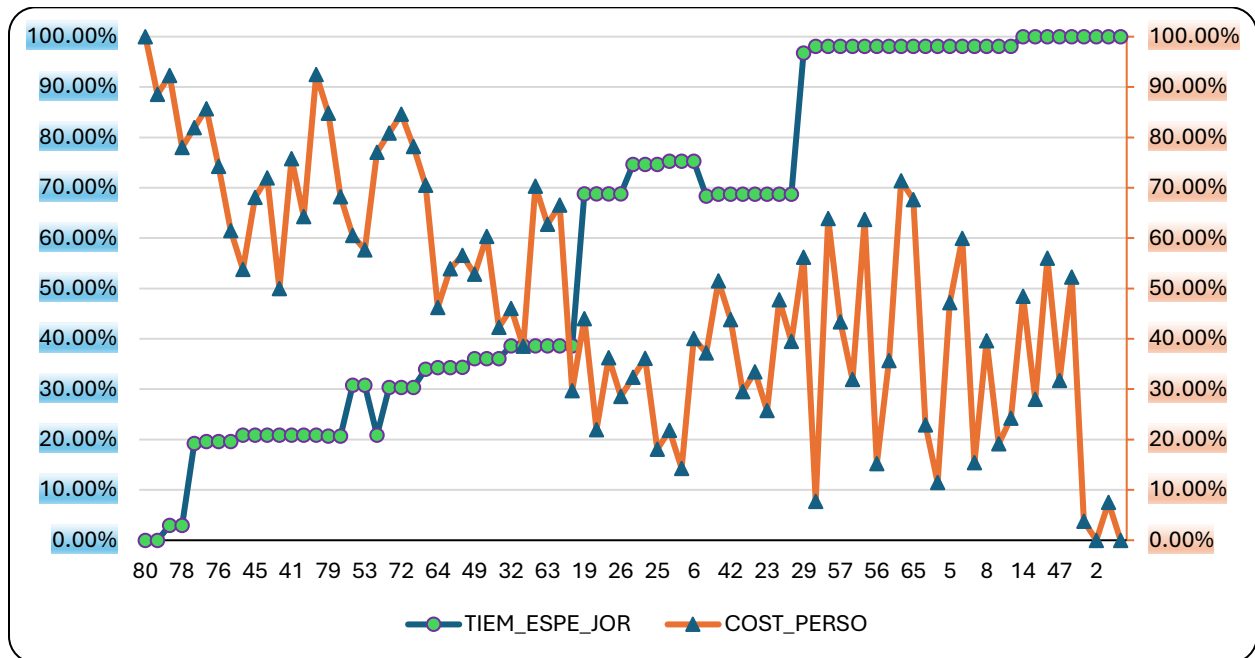
como criterio de decisión la minimización de los tiempos de espera. Teniéndose así la siguiente función objetivo.

$$\min Z = \sum_i \sum_j WT_{ij} \quad (23)$$


La ecuación 23 lo que busca es mostrar el comportamiento de los tiempos de espera sin tener en cuenta el comportamiento de los costos de recursos. En este sentido desde un enfoque analítico, se determina que, para eliminar los tiempos de espera, cada paciente debe ser atendido por un recurso exclusivo para él. Por lo tanto, el número mínimo de recursos necesarios para garantizar tiempos de espera nulos es de un tipo de recurso por cada paciente.

Para un total de tres pacientes, se pueden generar hasta 81 arreglos distintos en los cuales se alterna el número de recursos disponibles, dichos arreglos siguen el orden de n_h^t donde n representa el número de recursos de cada tipo h y t representa el número de recursos presentes ($n_1 * n_2 * n_3 * n_4 = 3 * 3 * 3 * 3 = 81$), el primer arreglo se presenta cuando se tiene la mínima cantidad de recursos ($R_1 = 1, R_2 = 1, R_3 = 1, R_4 = 1$, teniendo la configuración de $[1,1,1,1]$) y el último posible cuando se presenta la cantidad máxima, que para 3 pacientes es de 3 ($[3,3,3,3]$). La **Figura 14** ilustra el comportamiento de los 81 arreglos, con costos y tiempos de espera normalizados (tomando como 0% el menor de ellos y 100% el mayor), comparando el costo asociado al personal en cada escenario y el tiempo de espera generado en total.

Figura 14.
Análisis de escenarios

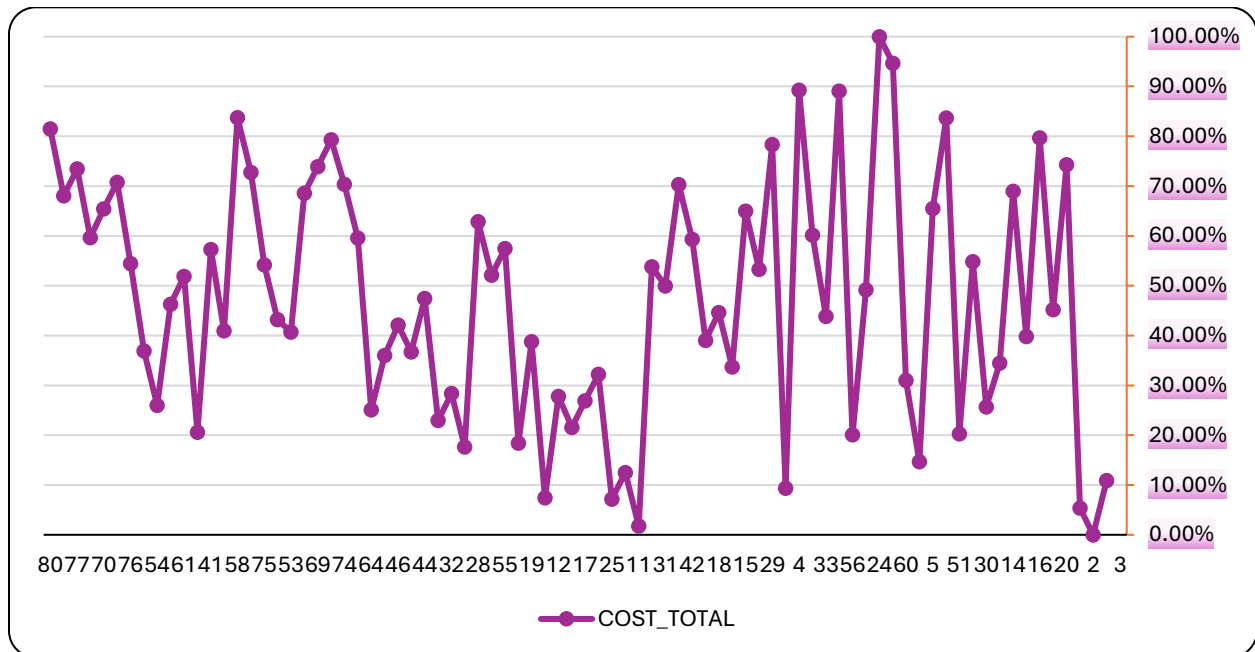


Esto se hace con el fin de buscar si existe un equilibrio entre el costo de personal y los tiempos de espera, de modo que cuanto más crecen los tiempos de espera, existe una tendencia decreciente en los costos. Una vez se general todos los escenarios, se penalizan los tiempos de espera con el costo incremento definido por Woodworth & Holmes, (2020) en donde se establece que para pacientes nivel 1 y 2 el incremento corresponde en promedio al 6% de los costos de atención (costos asociados al uso del recurso) de por cada 10 minutos de tiempos de espera (costos de los recursos) y para niveles 3,4 y 5 el incremento en promedio es del 3% por cada 10 minutos de tiempos de espera. La **Figura 15** muestra el comportamiento de los costos por tiempo de espera junto con el comportamiento de los costos de personal. Debido a que cada ED maneja costos diferentes, se toman costos de literatura asociados al costo del personal por día: $SC_1 = \$24,35$; $SC_2 = \$8$; $SC_3 = \$13,12$; $SC_4 = \$43,59$ (León, 2017).

Figura 15.*Costos de personal vs costos de tiempo de espera*

Una vez efectuado el costo de tiempo de espera, se ordenó para poder observar si mientras crecían los costos por esperar, los costos asociados a los recursos seguían disminuyendo, corroborando la premisa. Luego de esto se efectúa la suma de los costos de espera junto con los costos de recursos contemplando el costo total. La **Figura 16** representa el comportamiento de los costos totales.

Figura 16.
Comportamiento de costos totales



A partir de la **Figura 16** se puede observar que aparentemente existe un equilibrio en los escenarios, sin embargo, al mirar detenidamente se observa que el escenario 1 con la mínima cantidad de recursos (1,1,1,1) generan el máximo tiempo de espera, pero, paradójicamente esta combinación de escenarios ocasiona el menor costo total. Una vez generados los escenarios se ejecuta el modelo bajo las mismas condiciones de los escenarios, con la diferencia que el modelo ahora considera el número de recursos como una variable, ejecutándose directamente la función objetivo () con el fin de validar si el modelo representa correctamente el sistema diseñado.

Después de correr el modelo de optimización y en contraste con el análisis de escenarios los resultados se presentan en la **Tabla 15**.

Tabla 15.
Comparación de resultados

Modelo de optimización	Análisis de escenarios
Costos (Normalizados)	
0.0178%	0%
Tiempo computacional	
605.7 s	305.4 s*
<i>*Tiempo promedio de cada escenario evaluado</i>	

A partir de los resultados se observa que el modelo de optimización presenta una diferencia de 0.0178% lo que se asume como un error aceptable, concluyendo que el modelo es capaz de representar con un alto nivel de precisión lo que se pretende. Desde un punto de vista en un contexto real, la solución que se obtiene a través del modelo es válida ya que el modelo encuentra el equilibrio entre dos elementos, costo de recursos y tiempos de espera, al tratarse en esta validación de pocos pacientes los tiempos de espera presentes son tolerables y no es necesario incurrir en un aumento en el costo de recursos para disminuir el costo de tiempo de espera.

Luego de verificar y validar, se decidió explorar bajo las mismas condiciones, que sucedería si un paciente nivel 2 (triage clase 2), aumentaba su criticidad a nivel 1, encontrando que al hacer esto, hubo un incremento en los costos totales, pero con una disminución en costos por tiempo de espera, lo que indica que el ingreso de un paciente nivel 1 afecta el comportamiento del sistema dependiendo el momento en el cual ingrese.

9. Diseño experimental y análisis de resultados

Teniendo el modelo validado, parte esencial es la experimentación de este para la toma de decisiones dentro de un centro de salud. Por esta razón se definen instancias tomando como referencia lo encontrado en literatura.

9.1. Diseño experimental

A partir de lo encontrado en literatura se pretenden definir instancias para el número de pacientes que ingresan en un día a un ED, tomando como referencia lo descrito por Harzi et al., (2017), en donde se definen instancias de [5,10,15,20,25] pacientes. No obstante, al intentar adaptar estas instancias al sistema que se caracterizó con 12 actividades (en contraste con el de literatura que es de 4 actividades), se encuentra que existen limitaciones de memoria computacional debido al número de variables involucradas en el modelo diseñado. La **Tabla 16** muestra el número de variables involucradas en cada instancia.

Tabla 16.
Tamaño de instancias

Pacientes	Número de variables
3*	13.072
5	36.184
10	144.364
15	324.544
20	576.724
25	900.904
<i>*Instancia propia definida para la validación y verificación</i>	

Debido al crecimiento de las variables no fue posible ejecutar las instancias de 25, 20 y 15 pacientes, para la instancia de 10 pacientes se encuentra que luego de 7 horas el modelo no había encontrado una solución factible, esto se debe a que el modelo inicia explorando combinaciones de recursos y luego de encontrar una de ellas factible, empieza a explorar como se pueden organizar los pacientes de modo que se reduzca el tiempo de espera. Finalmente, para 5 pacientes el modelo

tardaba entre 45 y 480 minutos aproximadamente en encontrar solución exacta. Por esta razón para realizar experimentación al modelo, se decide tomar la instancia más pequeña (5 pacientes) obtenida en literatura definida por Harzi et al., (2017).

Para continuar con el diseño experimental se pretende por medio de análisis de sensibilidad del modelo generar escenarios independientes en donde bajo las mismas condiciones se van a afectar dos parámetros principalmente, en primer lugar, el tiempo de espera máximo que puede tener un paciente a lo largo del sistema y segundo la posición de llegada del paciente más crítico. La **Tabla 17** muestra las diferentes configuraciones.

Tabla 17.

Diseño experimental

Parámetro	Nivel
Máximo tiempo de espera	[60,120,180,240,300,360,420]
Posición de llegada del paciente clase 1	[1,2,3,4,5]*
<i>*Indica posición de llegada del paciente nivel 1</i>	

Para el diseño experimental, la generación de escenarios presenta un abanico de posibilidades amplio, teniendo escenarios posibles en donde todos los pacientes son de nivel 1 (más urgente), hasta el punto donde todos son nivel 5 (menos urgente), en este análisis, los cinco pacientes se asignan una única vez a posiciones aleatorias dentro del sistema, cada uno con un nivel de triage diferente. Posteriormente, se modifica la posición del paciente con triage nivel 1 para evaluar su impacto en la calidad de la solución y en el tiempo de cómputo. Se elige al paciente con clase 1 (más urgente), ya que su ingreso al sistema requiere una asignación inmediata de recursos y atención sin posibilidad de espera generando una posible carga al sistema. La **Figura 17** muestra el orden de cada escenario en donde i hace referencia al índice de llegada del paciente y el número al nivel de triage.

Figura 17.
Escenarios diseñados

E1	E2	E3	E4	E5
i1	i4	i4	i4	i4
i4	i1	i2	i2	i2
i2	i2	i1	i5	i5
i5	i5	i5	i1	i3
i3	i3	i3	i3	i1

Se busca analizar cómo varían los costos al aumentar o reducir el tiempo de espera máximo, considerando también la posición del paciente más crítico. Para ello, se establecen cinco niveles en los que todos los pacientes permanecen en la misma posición a excepción de cuando intercambian con el paciente con mayor urgencia. Cada escenario se cruza con los valores del tiempo máximo de espera (instancia).

9.2. Análisis de resultados

Para el análisis de resultados se hará desde dos perspectivas, la primera explora el comportamiento de los costos dentro de cada escenario y la segunda muestra el comportamiento de cada instancia entre los escenarios. De los cinco escenarios establecidos (**Figura 17**) se encuentra a lo largo de la experimentación que solo en el escenario 2 (E2) se pudo obtener resultado en todas las instancias diseñadas, esto se debe a que a medida que aumenta el tiempo máximo en cada instancia el espacio de búsqueda incrementa generando una mayor carga computacional, la **Tabla 18** muestra el tiempo computacional empleado en cada escenario para cada instancia ejecutada.

Tabla 18.
Tiempo computacional

		Tiempo computacional [seg]					
Instancia Escenario	60	120	180	240	300	360	420
E1	2185.97 s	9178.20 s	14298.10 s	18478.8 s	22478.1 s	27648.1 s	-*
E2	1450.14 s	7575.81 s	8834.10 s	9865.9 s	13928.7 s	18178.8 s	28478.9 s
E3	8834.10 s	12784.44 s	18136.70 s	21716.4 s	27486.5 s	-*	-*
E4	3364.14 s	11457.30 s	14364.72 s	19713.8 s	21784.2 s	28745.7 s	-*
E5	10839.20 s	17458.60 s	22475.10 s	-*	-*	-*	-*
*Sin respuesta							

En función del tiempo de ejecución, existen escenarios donde no fue posible obtener respuesta debido a que la memoria de la máquina en la que se ejecutó el modelo se llenaba y el modelo no había encontrado respuesta hasta ese momento. En consecuencia, con este hecho, se establece que para el primer análisis (en cada escenario) se presenta en todas las instancias por cada escenario generado, mientras que, para el análisis entre escenarios, solo se explora hasta la instancia 3 (Tiempo máximo de 180) puesto que es hasta la instancia que se tienen ejecuciones completas.

9.2.1. Análisis dentro del escenario

Como se mencionó anteriormente, un análisis importante se da al explorar como varía el comportamiento de los costos en función del máximo tiempo de espera (Ecuación 22) para cada escenario planteado (Ver **Figura 17**). Dentro de este análisis es posible establecer que cuanto menos tiempo de espera puede tolerar cada paciente, no solo vuelve inactivas algunas restricciones del modelo (Ecuación 22) para ciertas clases de pacientes, sino que los costos incrementan debido a que se necesita más recursos para poder cumplir con la atención.

A partir de esta premisa y como resultado, el modelo evalúa si hacer esperar a los demás pacientes genera un costo mayor que al agregar una unidad de cualquier tipo de recurso necesario,

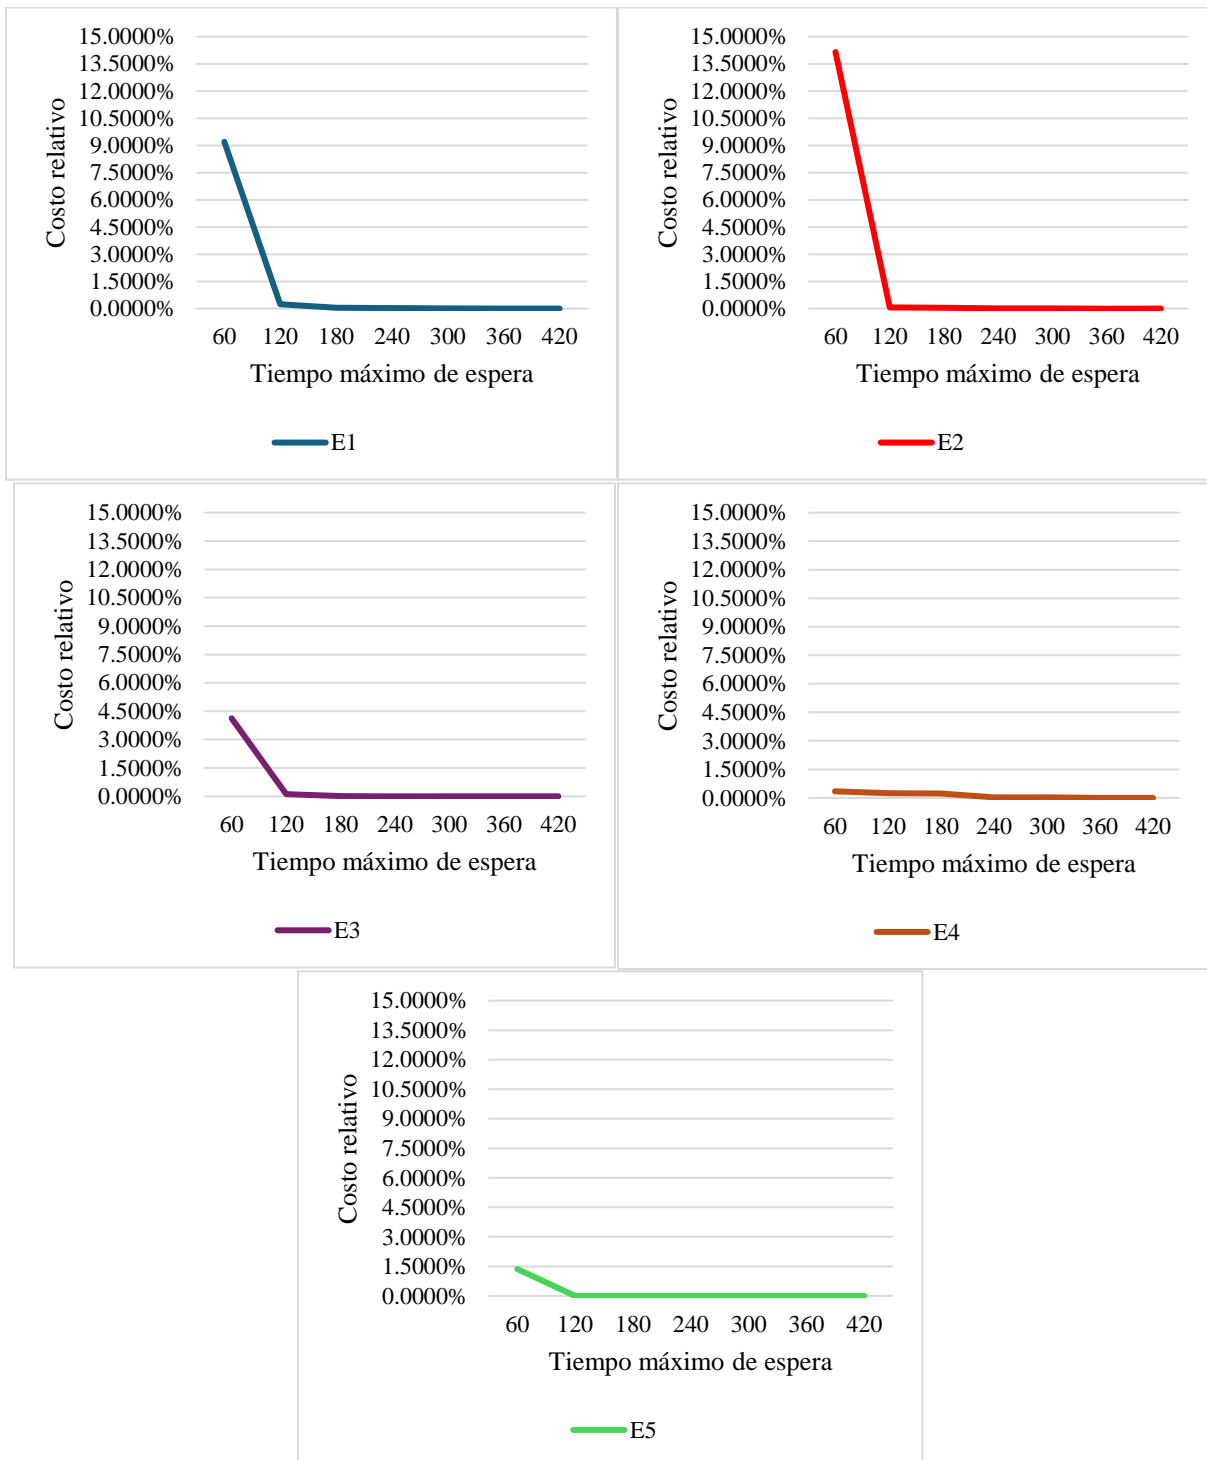
si es así, se agrega la unidad de recurso y se evalúa su impacto. Para observar el comportamiento del costo en cada escenario, este es relativizado, tomando como 0% el menor costo encontrado en cada escenario, y aplicando la siguiente operación.

$$E1i = \frac{Instancia_i - \min(Instancias)}{\min(Instancias)}$$

En este caso el índice i representa la instancia en cuestión para el escenario E1. La

Figura 18 muestra el comportamiento de los costos en términos porcentuales con respecto al menor costo obtenido por cada escenario.


Figura 18.
Comparación de escenarios



A partir de la **Figura 18** es posible establecer que para los escenarios propuestos de 5 pacientes el modelo tiende a una convergencia en una instancia de 180 minutos. Es importante

hacer la aclaración que, aunque el escenario E5 no es posible determinar su convergencia, se puede asumir un comportamiento similar a los otros cuatro casos planteados. Este análisis resulta útil puesto que indica que cuanto más se relaja el modelo (aumentando el tiempo de espera), solo aumenta la holgura de la restricción, pero no tiene un impacto significativo en los costos. La **Figura 19** muestra la cantidad de recursos de tipo humano (médico general, auxiliar, enfermera, especialista) en cada escenario para cada instancia.

Figura 19.
Número de recursos de tipo humano

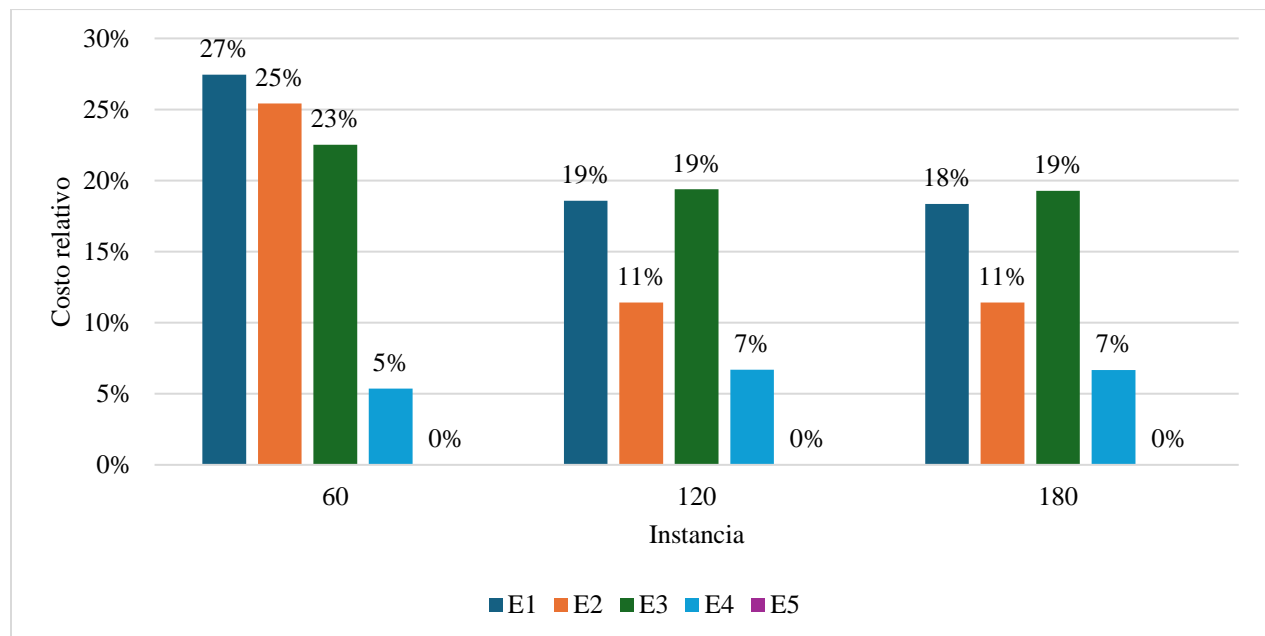


El comportamiento de esta gráfica refuerza la premisa de convergencia del modelo para cinco pacientes, en donde la variación en costo se debe a la secuenciación de pacientes y no a la adquisición de recursos en sí, donde se observa que el recurso uno (R1) es un recurso restrictivo de capacidad.

9.2.2. Análisis entre escenarios

En esta sección se explora el comportamiento de los costos relativizados tomando como referencia el menor costo en cada instancia, por razones mencionadas anteriormente, solo se explora hasta la instancia tres (Tiempo máximo de espera 180 minutos). En todas las instancias corridas se obtuvo que el menor costo en todos los casos corresponde al escenario cinco (E5) en donde el paciente más crítico llega en último lugar corresponde al menor costo, lo cual confirma que para cinco pacientes el impacto de los pacientes más críticos si afecta el sistema. La **Figura 20** muestra el comportamiento entre escenarios.

Figura 20.
Análisis entre escenarios



El comportamiento visto en la **Figura 20** se debe a que cuanto más tarde llega el paciente de nivel 1, el sistema no presenta una sobrecarga tan fuerte generando una disminución en los costos al no tener que designar personal de manera inmediata, mientras que cuando su llegada es

pronta el recurso se usa inmediatamente, haciendo que los demás estén obligados a esperar la disponibilidad de un recurso.

10. Conclusiones

A partir de esta investigación es posible concluir que una adecuada planeación de recursos, ayuda no solo en la minimización de recursos sino genera un impacto positivo en la satisfacción de los pacientes, esto se logra al momento de disminuir los tiempos de espera de cada paciente. Para la planeación y asignación de recursos es necesario la caracterización de pacientes desde elementos como el nivel de triage, momento de llegada y la ruta clínica de cada paciente, no obstante, este enfoque tiene elementos a consideración identificados en literatura:

- Para la clasificación de pacientes en niveles de triage es necesario considerar variables demográficas, sintomatológicos y el balance de clases, debido a que esto puede llevar a problemas de clasificación.
- El momento de llegada de los pacientes y la clase de estos influye en el comportamiento del sistema, por ello es necesario considerar en que franja o franjas horarias puede ingresar un mayor número de pacientes al sistema.
- El análisis de datos y caracterización del sistema resulta crucial para la planeación y asignación de recursos, considerando que el ingreso de pacientes, rutas clínicas y tiempos de atención a pacientes varían, trayendo cambios significativos en cada sistema.

Desde la perspectiva del modelo de optimización fue posible determinar que es útil para el apoyo en la toma de decisiones de tipo táctico-operativo, impactando en medidas de desempeño (ver **Tabla 2**), tales como el tiempo total de espera, costos totales y tiempo puerta médico. No obstante, debido al gasto computacional (**Tabla 18**) se hace necesaria la exploración de métodos para la búsqueda de soluciones rápidas que permiten la escalabilidad del problema y programación de recursos en un horizonte de tiempo mayor (semana, mes).

El modelo responde a la cantidad de recursos en función del número de pacientes y los tiempos máximos de espera bajo la condición de dar atención a todos los usuarios, esto puede ser un insumo para definir políticas que ayuden en la circulación del flujo de pacientes tales como liberar el sistema enviando pacientes a otros centros si llevan esperando un tiempo considerable, sin embargo, para ello es necesario poder ejecutar el modelo en instancias mayores, puesto que no es hasta el momento no es posible definir políticas, debido al número de pacientes. Por otra parte, el modelo es generalizable al uso de cualquier tipo de recursos y caracterización de cualquier sistema, lo que permite que pueda llegar a ser una herramienta teórica interesante para su implementación una vez se explore su comportamiento con metaheurísticas ya que debido a la complejidad y número de restricciones en instancias grandes como 20 pacientes no es posible encontrar solución óptima.

Finalmente, este trabajo de investigación permite el impacto teórico que ayuda en la mitigación del hacinamiento en departamentos de emergencia por medio de la planeación y asignación de personal.

11. Futuras investigaciones

Para futuras investigaciones se sugiere la implementación de metaheurísticas que ayuden en la exploración de soluciones y que por la complejidad del modelo y el número de restricciones presentes no es posible de momento encontrar solución factible en instancias grandes. Por otra parte, resulta interesante explorar el comportamiento de la función de costo con el fin encontrar otras maneras de penalizar los tiempos de espera. También se sugiere explorar si el orden de llegada de pacientes con otros niveles de triage genera un efecto en el comportamiento del sistema. Finalmente, debido a que se trata de un modelo teórico, se sugiere la posible modificación de restricciones con el fin de mejorar la convergencia de su la solución.

Referencias Bibliográficas

- Aboueljinane, L., & Frichi, Y. (2022). A simulation optimization approach to investigate resource planning and coordination mechanisms in emergency systems. *Simulation Modelling Practice and Theory*, 119. <https://doi.org/10.1016/j.simpat.2022.102586>
- Abraham, G., Byrnes, G. B., & Bain, C. A. (2009). Short-term forecasting of emergency inpatient flow. *IEEE Transactions on Information Technology in Biomedicine*, 13(3), 380–388. <https://doi.org/10.1109/TITB.2009.2014565>
- Ahmad, N., Ghani, N. A., Kamil, A. A., Tahar, R. M., & Teo, A. H. (2012). Evaluating emergency department resource capacity using simulation. *Modern Applied Science*, 6(11), 9–19. <https://doi.org/10.5539/mas.v6n11p9>
- Amaran, S., Sahinidis, N. V., Sharda, B., & Bury, S. J. (2016). Simulation optimization: a review of algorithms and applications. *Annals of Operations Research*, 240(1), 351–380. <https://doi.org/10.1007/s10479-015-2019-x>
- Andersen, A. R., Nielsen, B. F., Reinhardt, L. B., & Stidsen, T. R. (2019). Staff optimization for time-dependent acute patient flow. *European Journal of Operational Research*, 272(1), 94–105. <https://doi.org/10.1016/J.EJOR.2018.06.015>
- Batljan, I., & Lagergren, M. (2004). Inpatient/outpatient health care costs and remaining years of life—effect of decreasing mortality on future acute health care demand. *Social Science & Medicine*, 59(12), 2459–2466. <https://doi.org/10.1016/J.SOCSCIMED.2004.04.003>
- Birch, S., O'Brien-Pallas, L., Alksnis, C., Murphy, G. T., & Thomson, D. (2003). Beyond demographic change in human resources planning: An extended framework and application

to nursing. *Journal of Health Services Research and Policy*, 8(4), 225–229.
<https://doi.org/10.1258/135581903322403290>

Chen, T. L., & Wang, C. C. (2016). Multi-objective simulation optimization for medical capacity allocation in emergency department. *Journal of Simulation*, 10(1), 50–68.
<https://doi.org/10.1057/jos.2014.39>

Clasificación en Triage Urgencias | Datos Abiertos Colombia. (n.d.). Retrieved June 4, 2024, from
https://www.datos.gov.co/Salud-y-Proteccion-Social/Clasificacion-en-Triage-Urgencias/vt5n-eu2r/about_data

Daldoul, D., Nouaouri, I., Bouchriha, H., & Allaoui, H. (2018). A stochastic model to minimize patient waiting time in an emergency department. *Operations Research for Health Care*, 18, 16–25. <https://doi.org/10.1016/j.orhc.2018.01.008>

Etu, E. E., Monplaisir, L., Masoud, S., Arslanturk, S., Emakhu, J., Tenebe, I., Miller, J. B., Hagerman, T., Jourdan, D., & Krupp, S. (2022). A Comparison of Univariate and Multivariate Forecasting Models Predicting Emergency Department Patient Arrivals during the COVID-19 Pandemic. *Healthcare* 2022, Vol. 10, Page 1120, 10(6), 1120.
<https://doi.org/10.3390/HEALTHCARE10061120>

Fattahi, M., Keyvanshokoh, E., Kannan, D., & Govindan, K. (2023). Resource planning strategies for healthcare systems during a pandemic. *European Journal of Operational Research*, 304(1), 192–206. <https://doi.org/10.1016/j.ejor.2022.01.023>

Gallivan, S., & Utley, M. (2005). Modelling admissions booking of elective in-patients into a treatment centre. *IMA Journal of Management Mathematics*, 16(3), 305–315.
<https://doi.org/10.1093/imaman/dpi024>

- Ghannam, L. W., & Othman, M. (2023). Development of human resource scheduling model in the healthcare sector during the pandemic. *International Journal of Management Science and Engineering Management*. <https://doi.org/10.1080/17509653.2023.2183280>
- Graham, B., Bond, R., Quinn, M., & Mulvenna, M. (2018). Using Data Mining to Predict Hospital Admissions from the Emergency Department. *IEEE Access*, 6, 10458–10469. <https://doi.org/10.1109/ACCESS.2018.2808843>
- Gul, M., & Celik, E. (2020). An exhaustive review and analysis on applications of statistical forecasting in hospital emergency departments. *Health Systems*, 9(4), 263–284. <https://doi.org/10.1080/20476965.2018.1547348>
- Güler, M. G., & Geçici, E. (2020). A decision support system for scheduling the shifts of physicians during COVID-19 pandemic. *Computers and Industrial Engineering*, 150. <https://doi.org/10.1016/j.cie.2020.106874>
- Han, J., Kamber, M., & Pei, J. (2012). Data Mining Concepts and Techniques (3th ed.). *The Morgan Kaufmann*.
- Harzi, M., Condotta, J. F., Nouaouri, I., & Krichen, S. (2017). Scheduling Patients in Emergency Department by Considering Material Resources. *Procedia Computer Science*, 112, 713–722. <https://doi.org/10.1016/j.procs.2017.08.153>
- Hillier, F. S., & Lieberman, G. J. (2010). Introduction to Operations Research (9th ed.). *The McGraw-Hill Companies, Inc.* www.mhhe.com/hillier
- Hu, B., Jiang, G., Yao, X., Chen, W., Yue, T., Zhao, Q., & Wen, Z. (2023). Allocation of emergency medical resources for epidemic diseases considering the heterogeneity of epidemic areas.

Frontiers in Public Health, 11, 992197.

<https://doi.org/10.3389/FPUBH.2023.992197/BIBTEX>

Ismail, K., Thorwarth, M., & Arisha, A. (2014). Integrated decision support systems for improving emergency department performance in Irish hospitals. *International Journal of Operational Research*, 19(1), 40–59. <https://doi.org/10.1504/IJOR.2014.057843>

Jaotombo, F., Pauly, V., Fond, G., Orleans, V., Auquier, P., Ghattas, B., & Boyer, L. (2023). Machine-learning prediction for hospital length of stay using a French medico-administrative database. *Journal of Market Access and Health Policy*, 11(1). <https://doi.org/10.1080/20016689.2022.2149318>

Jiang, S., Chin, K. S., & Tsui, K. L. (2018). A universal deep learning approach for modeling the flow of patients under different severities. *Computer Methods and Programs in Biomedicine*, 154, 191–203. <https://doi.org/10.1016/J.CMPB.2017.11.003>

Johnson, M. R., Naik, H., Siang Chan, W., Greiner, J., Michaleski, M., Liu, D., Silvestre, B., McCarthy, I. P., McCarthy, I. P., Guido Carli, L., & Johnson, M. R. (2023). Forecasting ward-level bed requirements to aid pandemic resource planning: Lessons learned and future directions. *Health Care Management Science*, 26, 477–500. <https://doi.org/10.1007/s10729-023-09639-2>

Keshtkar, L., Salimifard, K., & Faghih, N. (2015). A simulation optimization approach for resource allocation in an emergency department. *QScience Connect*, 2015(1). <https://doi.org/10.5339/connect.2015.8>

- Kim, S. W., Li, J. Y., Hakendorf, P., Teubner, D. J. O., Ben-Tovim, D. I., & Thompson, C. H. (2014). Predicting admission of patients by their presentation to the emergency department. *Emergency Medicine Australasia*, 26(4), 361–367. <https://doi.org/10.1111/1742-6723.12252>
- Lee, M. L., Park, I., Park, D. U., & Park, C. (2017). Constrained ranking and selection for operations of an emergency department. *International Journal of Simulation Modelling*, 16(4), 563–575. [https://doi.org/10.2507/IJSIMM16\(4\)1.388](https://doi.org/10.2507/IJSIMM16(4)1.388)
- León, M. X. (2017). Costos directos del cuidado paliativo domiciliario para pacientes con cáncer gástrico estadio IV en Colombia*. *Universitas Médica*, 57(3), 294–306. <https://doi.org/10.11144/javeriana.umed57-3.cdcp>
- López De Castro, F., & Alcalá, F. J. R. (2003). *Planificación sanitaria (I)*.
- Luo, J. (2014). Integrating the huff model and floating catchment area methods to analyze spatial access to healthcare services. *Transactions in GIS*, 18(3), 436–448. <https://doi.org/10.1111/tgis.12096>
- Luo, L., Luo, L., Zhang, X., & He, X. (2017). Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models. *BMC Health Services Research*, 17(1), 1–13. <https://doi.org/10.1186/S12913-017-2407-9/TABLES/10>
- Luo, L., Xu, X., Li, J., & Shen, W. (2017). Short-term forecasting of hospital discharge volume based on time series analysis. *2017 IEEE 19th International Conference on E-Health Networking, Applications and Services, Healthcom 2017, 2017-December*, 1–6. <https://doi.org/10.1109/HealthCom.2017.8210801>

- Mathauer, I., & Wittenbecher, F. (2013). Hospital payment systems based on diagnosis-related groups: experiences in low-and middle-income countries. *Bull World Health Organ.* <https://doi.org/10.2471/BLT.12.115931>
- McRae, S. (2021). Long-term forecasting of regional demand for hospital services. *Operations Research for Health Care*, 28. <https://doi.org/10.1016/j.orhc.2021.100289>
- Mekhaldi, R. N., Caulier, P., Chaabane, S., Chraibi, A., & Piechowiak, S. (2021). A Comparative Study of Machine Learning Models for Predicting Length of Stay in Hospitals. *Journal of Information Science and Engineering*, 37(5), 1025–1038. [https://doi.org/10.6688/JISE.202109_37\(5\).0003](https://doi.org/10.6688/JISE.202109_37(5).0003)
- Mizan, T., & Taghipour, S. (2022). Medical resource allocation planning by integrating machine learning and optimization models. *Artificial Intelligence In Medicine*, 134, 933–3657. <https://doi.org/10.1016/j.artmed.2022.102430>
- Moosavi, A., & Ebrahimnejad, S. (2018). *Scheduling of elective patients considering upstream and downstream units and emergency demand using robust optimization.* <https://doi.org/10.1016/j.cie.2018.04.047>
- Munavalli, J. R., Rao, S. V, Srinivasan, A., Manjunath, U., & van Merode, G. G. (2017). A Robust Predictive Resource Planning under Demand Uncertainty to Improve Waiting Times in Outpatient Clinics. *Journal of Health Management*, 19(4), 563–583. <https://doi.org/10.1177/0972063417727627>
- Murphy, G. T., MacKenzie, A., Alder, R., Langley, J., Hickey, M., & Cook, A. (2013). Pilot-testing an applied competency-based approach to health human resources planning. *Health Policy and Planning*, 28(7), 739–749. <https://doi.org/10.1093/HEAPOL/CZS115>

- Peck, J. S., Gaehde, S. A., Nightingale, D. J., Gelman, D. Y., Huckins, D. S., Lemons, M. F., Dickson, E. W., & Benneyan, J. C. (2013). Generalizability of a simple approach for predicting hospital admission from an emergency department. *Academic Emergency Medicine, 20*(11), 1156–1163. <https://doi.org/10.1111/acem.12244>
- Qian, Z., Alaa, A. M., & van der Schaar, M. (2021). CPAS: the UK's national machine learning-based hospital capacity planning system for COVID-19. *Machine Learning, 110*(1), 15–35. <https://doi.org/10.1007/s10994-020-05921-4>
- Rais, A., & Viana, A. (2011). Operations Research in Healthcare: a survey. *International Transactions in Operational Research, 18*(1), 1–31. <https://doi.org/10.1111/J.1475-3995.2010.00767.X>
- Randolph, J. (2019). A Guide to Writing the Dissertation Literature Review. *Practical Assessment, Research, and Evaluation, 14*(1), 13. <https://doi.org/https://doi.org/10.7275/b0az-8t74>
- Rawat, S. S., & Sultana, R. (2021). Advance resource planning in hospital emergency departments using machine learning techniques. *International Journal of Human Capital and Information Technology Professionals, 12*(3), 74–86. <https://doi.org/10.4018/IJHCITP.2021070105>
- Rotter, T., Jong, R. B. de, Lacko, S. E., Ronellenfitch, U., & Kinsman, L. (2019). *Clinical pathways as a quality strategy*. <https://www.ncbi.nlm.nih.gov/books/NBK549262/>
- Sarno, D., & Nenni, M. E. (2016). Daily nurse requirements planning based on simulation of patient flows. *Flexible Services and Manufacturing Journal, 28*(3), 526–549. <https://doi.org/10.1007/s10696-015-9231-5>
- Soler, W., Gómez Muñoz, M., Bragulat, E., & Álvarez, A. (2010). Triage: a key tool in emergency care. In *An. Sist. Sanit. Navar* (Vol. 33).

- Stoeck, T., & Mellouli, T. (2021). A Two-Dimensional Categorization Scheme for Simulation/Optimization-Based Decision Support in Hospitals Applied to Overall Bed Management in Interdependent Wards Under Flexibility. In *Operations Research and Simulation in Healthcare*. Springer International Publishing. https://doi.org/10.1007/978-3-030-45223-0_1
- Sun, Y., Heng, B. H., Seow, Y. T., & Seow, E. (2009). Forecasting daily attendances at an emergency department to aid resource planning. *BMC Emergency Medicine*, 9(1), 1–9. <https://doi.org/10.1186/1471-227X-9-1/FIGURES/5>
- Taboada, M., Cabrera, E., Luque, E., Epelde, F., & Iglesias, M. L. (2013). Modeling, simulation and optimization of resources management in hospital emergency departments using the agent-based approach. In *Advances in Computational Modeling Research: Theory, Developments and Applications*. Nova Science Publishers, Inc. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84892105270&partnerID=40&md5=d96d7e021adb3acb51b07bf14327992d>
- Tello, M., Reich, E. S., Puckey, J., Maff, R., Garcia-Arce, A., Bhattacharya, B. S., & Feijoo, F. (2022). Machine learning based forecast for the prediction of inpatient bed demand. *BMC Medical Informatics and Decision Making*, 22(1), 1–13. <https://doi.org/10.1186/S12911-022-01787-9/FIGURES/7>
- Tohidi, M., Kazemi Zanjani, M., & Contreras, I. (2021). A physician planning framework for polyclinics under uncertainty. *Omega*, 101, 102275. <https://doi.org/10.1016/J.OMEGA.2020.102275>

- Woodworth, L., & Holmes, J. F. (2020). JUST A MINUTE: THE EFFECT OF EMERGENCY DEPARTMENT WAIT TIME ON THE COST OF CARE. *Economic Inquiry*, 58(2), 698–716. <https://doi.org/10.1111/ecin.12849>
- Xu, M., Wong, T. C., & Chin, K. S. (2014). A medical procedure-based patient grouping method for an emergency department. *Applied Soft Computing Journal*, 14(PART A), 31–37. <https://doi.org/10.1016/j.asoc.2013.09.022>
- Yousefi, M., Yousefi, M., Ferreira, R. P. M., Kim, J. H., & Fogliatto, F. S. (2018). Chaotic genetic algorithm and Adaboost ensemble metamodeling approach for optimum resource planning in emergency departments. *Artificial Intelligence in Medicine*, 84, 23–33. <https://doi.org/10.1016/J.ARTMED.2017.10.002>
- Zaerpour, F., Bischak, D. P., Menezes, M. B. C., McRae, A., & Lang, E. S. (2020). Patient classification based on volume and case-mix in the emergency department and their association with performance. *Health Care Management Science*, 23(3), 387–400. <https://doi.org/10.1007/S10729-019-09495-Z/TABLES/9>
- Zhang, T., Lu, Y., Guan, Y., Zhong, X., & Hogan, T. (2023). Data-Driven Modeling and Analysis for COVID-19 Pandemic Hospital Beds Planning. *IEEE Transactions on Automation Science and Engineering*, 20(3), 1551–1564. <https://doi.org/10.1109/TASE.2022.3224171>

Anexo A. Análisis bibliométrico

Anexo B. Pseudocódigo del modelo de optimización programado en MATLAB

Anexo C. Resultados de la experimentación

Anexo D. Caracterización de tratamientos