

**Modelo para el cálculo de capacidad instalada en servicios de atención domiciliaria en
Clínicos IPS**

José Alberto Acevedo Salcedo

Asesor:

Nidia Danigza Lugo Lopez

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización en Ciencia de Datos y Analítica

2024

Dedicatoria

A mis padres, quienes con su amor, sacrificio y apoyo constante han sido la inspiración y la fuerza motriz tras mis logros académicos.

A mis profesores, cuyos conocimientos y enseñanzas han moldeado mi camino y han despertado en mí una pasión por aprender y descubrir.

A mis amigos, por su comprensión, paciencia y compañía durante este arduo viaje. Gracias por estar a mi lado en cada paso del camino.

Y, finalmente, a todos aquellos profesionales de la salud de clínicos IPS que, con su dedicación y esfuerzo, mejoran la calidad de vida de las personas a través de su invaluable labor en la atención domiciliaria. Este trabajo está dedicado a ustedes, en reconocimiento de su compromiso y entrega diaria.

Agradecimientos

Quiero expresar mi más profundo agradecimiento a todas las personas y entidades que hicieron posible la realización de esta monografía.

A mis padres, por su incondicional amor y apoyo en cada paso de mi vida académica y personal.

Sus sacrificios y enseñanzas han sido fundamentales para alcanzar este logro.

A mis profesores y tutores de la Universidad Nacional Abierta y a Distancia – UNAD, especialmente a mi asesor de monografía, cuyo conocimiento, paciencia y orientación fueron cruciales para el desarrollo de este proyecto. Sus comentarios y sugerencias han enriquecido significativamente este trabajo.

A mis compañeros de estudio, por su amistad, colaboración y por compartir conmigo este viaje lleno de desafíos y aprendizajes. Sus palabras de aliento y apoyo han sido una fuente constante de motivación.

A las instituciones de salud y profesionales que participaron en este estudio, por su valiosa colaboración y disposición para compartir su experiencia y conocimientos. Su contribución ha sido esencial para el desarrollo de este trabajo.

Al personal administrativo de la UNAD, por su eficiencia y amabilidad en la gestión de los recursos necesarios para la realización de esta investigación.

A mi familia y amigos, por su comprensión y paciencia durante los momentos de estrés y dedicación que este proyecto requirió. Su presencia y apoyo incondicional me dieron la fuerza para seguir adelante.

Finalmente, agradezco a Dios por darme la salud, la fuerza y la sabiduría necesarias para completar esta etapa de mi vida académica.

Resumen

Este proyecto tiene como objetivo desarrollar una estrategia logística que mejore la distribución de recursos humanos y materiales en los servicios de atención domiciliaria de clínicos IPS en Bogotá, asegurando una atención eficiente y de alta calidad mediante técnicas de Machine Learning. Para ello, se identificarán las variables clave en el proceso de atención domiciliaria, revisando estudios de caso, literatura relevante y datos históricos. Además, se investigó el uso actual de Machine Learning en la logística de la salud para crear un marco teórico sobre su implementación y efectividad. Finalmente, se esbozan las estrategias basadas en modelos de Machine Learning u otras alternativas relacionadas la ciencia de datos para garantizar una distribución óptima de los recursos. Este enfoque busca no solo optimizar la eficiencia operativa de los servicios de atención domiciliaria sino también mejorar la calidad del servicio prestado a una población en crecimiento, con patologías crónicas y cada vez más longeva.

Palabras clave: salud, aprendizaje automático, aprendizaje supervisado, no supervisado

Abstract

This project aims to develop a logistics strategy that improves the distribution of human and material resources in the home care services of IPS clinics in Bogotá, ensuring efficient and high-quality care through Machine Learning techniques. To do this, the key variables in the home care process will be identified, reviewing case studies, relevant literature and historical data. Additionally, the current use of Machine Learning in healthcare logistics be investigated to create a theoretical framework on its implementation and effectiveness. Finally, strategies based on Machine Learning models or other alternatives related to data science be outlined to guarantee optimal distribution of resources. This approach seeks not only to optimize the operational care of home services but also to improve the quality of the service provided to a growing population, with chronic pathologies and increasingly long-lived.

Keywords: health, machine learning, supervised learning, unsupervised learning

Tabla de Contenido

Introducción	1
Planteamiento del Problema	2
Justificación	7
Objetivos	9
Objetivo General	9
Objetivos Específicos	9
Marco Conceptual	10
Marco Teórico.....	12
Variables Planeación Atención Domiciliaria.....	14
Resultados	15
Aplicación de la Ciencia de Datos a Logística Sanitaria	18
Estrategias de Distribución de Recursos a partir de Modelos de Machine Learning	24
Introducción.....	24
Identificación de Variables Clave para Colombia.....	24
Estrategia Propuesta para el Uso de Machine Learning	25
Etapa 1: Análisis Predictivo	25
Etapa 2: Optimización de Rutas y Recursos	26
Implementación y Evaluación.....	26
Conclusiones.....	28

Referencias Bibliográficas32

Lista de Tablas

Tabla 1 <i>Matriz de Correspondencia de Técnicas de Machine Learning y Variables en Investigaciones sobre Planificación de Atención Médica Domiciliaria.....</i>	19
---	----

Lista de Figuras

Figura 1	<i>Aplicación de Técnicas de Ciencia de Datos en Logística Sanitaria</i>	20
-----------------	--	----

Lista de Apéndices

Apéndice A <i>Glosario</i>	39
---	----

Introducción

En la interacción de la tecnología y la atención de salud, este trabajo se embarca en la tarea de optimizar los recursos para la prestación de servicios de atención domiciliaria en áreas urbanas, particularmente en Bogotá, mediante la aplicación de técnicas de la ciencia de datos. Este proyecto aborda las complejidades de la logística y operación de la atención domiciliaria y se propone como respuesta a las crecientes demandas de un sistema de salud presionado por el dinamismo de una población en aumento y el desafío del envejecimiento demográfico. A través de este documento, se busca presentar un plan detallado que refleje los puntos de vista y metodologías adoptadas durante la investigación, anticipando posibles objeciones y respondiendo a las críticas, en un esfuerzo por mejorar continuamente el alcance y la precisión del planteamiento estratégico propuesto.

Es importante reconocer que, si bien el empleo de la ciencia de datos en la salud pública está en una etapa emergente, la propuesta aquí presentada se cimenta en la creencia de que las soluciones innovadoras pueden y deben ser aplicadas para optimizar la efectividad y eficiencia de los servicios de salud. Por tanto, este trabajo no solo se enfoca en la optimización de recursos, sino que también busca plantear estrategias que rompan con el paradigma en la gestión sanitaria, donde la tecnología actúa como estimulante para el desarrollo de servicios de atención domiciliaria más accesibles y de mayor calidad. Con este documento, se busca explorar las posibilidades que ofrecen la ciencia de datos en la salud.

Planteamiento del Problema

En el ámbito de la programación de los servicios de salud, una variedad de factores asegura los escenarios fundamentales para la atención al usuario, destacando especialmente las condiciones técnico-administrativas. Estos factores abarcan aspectos legales, financieros, administrativos, logísticos y de gestión de recursos humanos, de acuerdo con el (Resolución 3100, 2019). Estos componentes no solo influyen en la eficacia de la prestación del servicio de salud, sino que igualmente alteran la admisión de usuarios en diversas especialidades médicas. De igual manera son cruciales para la asignación eficiente de recursos, considerando las restricciones del servicio, y se alinean con lo establecido en la resolución 3100 de 2019.

A nivel general, la preocupación por la gestión logística en el acceso a los servicios de salud es indudable. El servicio de Atención Médica Domiciliaria (HHC, por sus siglas en inglés) se ha convertido en una piedra angular de la asistencia sanitaria moderna, especialmente debido a su rápida expansión propiciada por el envejecimiento de la población. Esta tendencia demográfica, acompañada de un creciente deseo de evitar hospitales, particularmente durante circunstancias críticas como la reciente pandemia de COVID-19, ha aumentado significativamente la demanda de estos servicios. Durante la pandemia, los hospitales se convirtieron en focos de infección, lo que llevó a muchas personas a preferir recibir atención médica en casa para minimizar el riesgo de contagio (Sabetkish & Rahmani, 2021).

En Estados Unidos, el número de centros de HHC aumentó de 8,618 en 2006 a 11,593 en 2017. De manera similar, entre 2015 y 2016, se estima que el 6.4 % de los hogares canadienses se beneficiaron de la atención domiciliaria (Xie et al., 2023). En Colombia, aunque los datos específicos no son tan detallados, un estudio reciente indicó que la demanda de servicios de atención médica domiciliaria también ha visto un incremento notable, reflejando tendencias similares a las observadas en Norteamérica (Secretaría de Salud, 2021).

Frente a esta creciente demanda y la inherente incertidumbre de las necesidades de servicio, surge el desafío de planificar de manera óptima la capacidad para la prestación de los servicios de HHC.

Lo anterior lleva a pensar en una gestión eficaz de los recursos humanos en la atención médica domiciliaria se presenta como un problema complejo debido a la naturaleza evolutiva de las necesidades de los pacientes a lo largo del tiempo. Este reto es multifacético y se debe a varios factores críticos. Primero, la alta rotación de personal es un problema significativo en el sector de la atención domiciliaria, con tasas que pueden superar el 60% en algunas agencias. Esta alta rotación incrementa la carga de trabajo de los cuidadores restantes, lo que afecta negativamente la moral y la calidad de la atención proporcionada. Además, la carga de trabajo adicional puede llevar al agotamiento del personal, exacerbando aún más el problema de retención (Möckli et al., 2021)

En segundo lugar, la gestión de las diferencias culturales entre cuidadores y pacientes es otro reto. Los cuidadores a menudo deben atender a personas de diversas edades, orígenes socioeconómicos y etnias, lo cual puede generar situaciones desafiantes sin la formación adecuada para manejar estas dinámicas (Qin et al., 2023). Sin embargo, a medida que las condiciones y requerimientos de los pacientes cambian, el tipo y la frecuencia de las visitas necesarias se ajustan, planteando desafíos significativos para la planificación a corto plazo y la asignación de personal (Yalçındağ & Lanzarone, 2022). La necesidad de dar la continuidad del cuidado complica aún más este escenario, pues las asignaciones actuales podrían resultar insostenibles, desembocando en sobrecargas de trabajo y la necesidad de reorganizar las asignaciones de pacientes, lo cual potencialmente perjudica la calidad de la atención.

En concordancia con lo anterior, la pandemia ha subrayado un problema crucial en la región de las Américas: la alarmante escasez de recursos humanos. Partiendo de que para la

atención domiciliaria es indispensable el recurso humano, en las Américas se evidencia una escasez de este, como se pudo evidenciar durante la pandemia del COVID-19 (Organización Panamericana de la Salud, 2023). En particular, Colombia, junto con otros países como Chile, Ecuador y Perú, proyectó un déficit inicial de 34,261 trabajadores de salud adicionales necesarios para responder adecuadamente a la pandemia. Este déficit representó entre el 0.54% y el 4.17% del total de recursos humanos en salud en estos países. Las medidas para abordar esta escasez incluyeron la contratación y despliegue de personal adicional, así como la reasignación de personal existente para cubrir las necesidades emergentes (Bustamante et al., 2023).

Además, la distribución desigual de los recursos humanos en salud evidencia la ausencia de políticas robustas de planificación y desarrollo profesional. Esta situación crítica ha revelado que un porcentaje significativo de países en el Caribe y Latinoamérica, específicamente entre el 66.0% y el 93.9%, no cumplen con los umbrales de recursos humanos en salud establecidos para alcanzar las metas de los Objetivos de Desarrollo Sostenible, particularmente el objetivo de lograr la cobertura sanitaria universal. Esto incluye la protección contra los peligros económicos, el acceso a servicios de salud primordiales y el acceso a medicamentos y vacunas seguros, eficaces, asequibles y de calidad para todos. Para el año 2030, se estima que la brecha en la disponibilidad de profesionales de la salud oscilará entre 600,000 y 2 millones, lo que pone en peligro la prestación de los servicios de salud (Organización Panamericana de la Salud, 2023).

En el caso específico de Colombia, el sistema de salud enfrenta el reto crítico de optimizar su talento humano. Aunque para el año 2016 se contabilizaban más de 563 mil integrantes en el sector, con un 55% de profesionales y un 45% de técnicos y auxiliares, existe una discrepancia notable entre la formación de estos recursos y su empleabilidad efectiva dentro del área asistencial (Ministerio de Salud y Protección Social, 2018). Esta situación se ve agravada por una distribución geográfica desigual del talento humano en salud, que favorece a las zonas

urbanas en detrimento de las rurales, generando barreras significativas para el acceso y la calidad del cuidado de la salud en las comunidades más alejadas.

Sumado a lo anterior, el talento humano en salud en Colombia afronta condiciones laborales que limitan su desarrollo profesional y personal, restringiendo su autonomía y capacidad para proporcionar servicios de salud de alta calidad y satisfacer adecuadamente la demanda de profesionales calificados. Es esencial destacar la imperiosa necesidad de alinear las políticas de salud con los mandatos de las leyes vigentes en términos de autonomía y dignidad de los trabajadores, conforme a lo establecido en la Ley 1164 de 2007 de Talento Humano en Salud. Esta política aborda el desajuste entre la oferta educativa para profesionales de la salud y las demandas del mercado laboral, así como la mala distribución y las condiciones laborales deficientes, lo que contribuye a los desafíos que enfrenta el sistema de salud colombiano para asegurar su viabilidad y sostenibilidad. Es crucial garantizar la cobertura y calidad del servicio en todo el territorio nacional, independientemente de la modalidad de prestación. Como se menciona en el documento de política,

La política busca orientar las acciones de los agentes que intervienen en los mercados educativo, laboral y de servicios de salud a partir del reconocimiento de sus características, particularmente la descentralización, la autonomía de sus instituciones, la participación de agentes privados y la interacción de elementos regulatorios y de mercado en la dinámica de cada uno de ellos (Dirección de Desarrollo del Talento Humano en Salud, 2018, p. 84).

En países como Estados Unidos y Reino Unido, se han utilizado técnicas de Machine Learning y ciencia de datos para mejorar la logística en la atención domiciliaria, resultando en mejoras significativas en eficiencia y reducción de costos. Estos avances, sin embargo, han enfrentado desafíos como la calidad de los datos y la integración con los sistemas de salud existentes (Yoshizaki, 2018).

En América Latina, la adopción de estas tecnologías es aún incipiente. Un estudio del Banco Interamericano de Desarrollo (BID, 2021) destaca que la región tiene un rendimiento logístico considerablemente inferior en comparación con las economías avanzadas, lo que afecta su competitividad y productividad. La pandemia de COVID-19 ha subrayado la necesidad urgente de mejorar los sistemas de información y la capacidad logística para enfrentar emergencias sanitarias (Leeftink et al., 2018).

En este contexto, se propone realizar una validación bibliográfica para generar una estrategia logística integral en los prestación de atención domiciliaria de clínicos IPS en Bogotá. Dicha estrategia tomará en cuenta variables críticas como el talento humano, infraestructura, tiempo disponible y georreferenciación de pacientes, dentro de los marcos restrictivos del sistema de salud. Se enfatizará en la importancia de la revisión de literatura y estudios previos, particularmente en aquellos que aplican el Machine Learning y la ciencia de datos en general, para optimizar la eficiencia y gestión logística del servicio.

Pregunta.

¿Qué características debe tener una estrategia logística que garanticen una adecuada distribución de los recursos humanos y materiales de clínicos IPS, garantizando una atención eficiente y de alta calidad para los pacientes, mediante el uso de técnica de Machine Learning?

Justificación

La concepción de una estrategia logística integral para Clínicos IPS exige un entendimiento profundo de las variables dinámicas multifacéticas que configuran el servicio de atención domiciliaria. Esta estrategia, sustentada por el uso de técnicas avanzadas de Machine Learning, promete no solo una distribución eficaz de recursos, sino también la promoción de un servicio de alta calidad para los pacientes. En este sentido, la adaptabilidad frente a la incertidumbre, una característica inherente de los modelos basados en Machine Learning, se alinea con las complejidades de la planificación de la atención médica domiciliaria descritas por Xie et al. (2023) y Yalçındağ y Lanzarone (2022).

La logística sanitaria se ve directamente influenciada por la variabilidad y la incertidumbre en la demanda y la oferta, lo cual resalta la relevancia de integrar enfoques robustos de optimización y Machine Learning, tal como sugieren Xie et al. (2023) en su investigación sobre la planificación de la capacidad de servicio. Al mismo tiempo, Yalçındağ y Lanzarone (2022) destacan los desafíos que surgen de la necesidad de mantener la continuidad del cuidado, subrayando la importancia de una asignación y una gestión flexibles del personal, algo que se puede potenciar significativamente mediante algoritmos predictivos y adaptativos.

La estrategia logística propuesta incorpora conocimientos provenientes de estudios actuales y datos históricos para anticiparse a los desafíos emergentes en la prestación de servicios de salud a domicilio. La ambición de utilizar Machine Learning refleja una búsqueda de eficiencia y optimización, además de un compromiso con la calidad y accesibilidad del servicio de salud para todos los pacientes, independientemente de su ubicación geográfica o condición.

Para asegurar la viabilidad y sostenibilidad del sistema de salud, y en respuesta a la escasez y distribución desigual de los recursos humanos de salud resaltados por la Organización Panamericana de la Salud (2023), la implementación de Machine Learning en la planificación

logística representa una solución innovadora. Esta estrategia se alinea con los esfuerzos de Colombia para mejorar la distribución geográfica y las circunstancias de contratación del talento humano en salud, procurando un sistema que respete la dignidad y autonomía de sus trabajadores, como lo exige la Ley.

La propuesta de esta monografía valida bibliográficamente la viabilidad de una estrategia logística integral para los servicios de atención domiciliaria de Clínicos IPS en Bogotá, con el objetivo de enfrentar los retos actuales y establecer un camino para futuras mejoras y adaptaciones. Implementar una estrategia basada en técnicas de Machine Learning y ciencia de datos optimiza la distribución de recursos humanos y materiales, mejorando la eficiencia y calidad de los servicios. Los principales beneficiarios son los pacientes, quienes reciben una atención más rápida y precisa, y el personal de salud, que experimenta una mejor organización y gestión de su trabajo, reduciendo el estrés y aumentando la satisfacción laboral. Además, Clínicos IPS se beneficia al ofrecer un servicio más competitivo y eficiente, lo que puede traducirse en una mayor sostenibilidad y crecimiento de la institución.

Objetivos

Objetivo General

Estructurar una estrategia logística que garanticen una adecuada distribución de los recursos humanos y materiales de clínicos IPS, garantizando una atención eficiente y de alta calidad para los pacientes, mediante el uso de técnica de Machine Learning.

Objetivos Específicos

Identificar las variables que intervienen en el proceso de servicio de atención domiciliaria de Clínicos IPS, basándose en estudios de caso, referentes bibliográficos y datos históricos.

Investigar aplicaciones existentes de la ciencia de datos en logística sanitaria que establezca un marco teórico sobre su implementación y efectividad.

Bosquejar un conjunto de estrategias a partir de modelos de Machine Learning garantizando la adecuada distribución de los recursos que intervienen en el proceso de atención domiciliaría.

Marco Conceptual

Gestión Logística en Salud comprende la coordinación eficiente de los recursos médicos, como medicamentos, equipos y suministros, desde la adquisición hasta la distribución y almacenamiento. Esta disciplina asegura la accesibilidad y eficiencia de los servicios de salud, optimizando la calidad de atención y minimizando desperdicios y costos. Según la Organización Mundial de la Salud (2023), una logística eficaz es crucial para responder de manera oportuna a las necesidades cambiantes de la salud pública. La gestión eficaz de los recursos logísticos en salud es fundamental para asegurar que los servicios médicos y los suministros sean accesibles (Organización Mundial de la Salud, 2023). La logística sanitaria es esencial para el funcionamiento eficiente del sistema de salud, garantizando que los recursos lleguen a donde se necesitan cuando se necesitan.

Ciencia de Datos se define como el campo interdisciplinario que utiliza técnicas científicas, procesos, algoritmos y sistemas para extraer conocimientos e información tanto de datos estructurados como no estructurados. Este campo integra técnicas de diferentes áreas como matemáticas, estadística, informática y ciencia de la información para procesar y analizar grandes cantidades de datos. Según Brown & Anderson (2023), la ciencia de datos implica la producción, procesamiento, análisis e interpretación de datos de manera principada y con un propósito definido para realizar avances significativos en diversas disciplinas. La ciencia de datos permite transformar grandes volúmenes de datos en información útil, apoyando la toma de decisiones basada en evidencia.

Georreferenciación es el proceso de asignar información espacial a datos, lo que permite que dichos datos sean representados en un mapa geográfico. Este proceso es esencial para convertir datos como direcciones, coordenadas o cualquier otra descripción de ubicación en puntos mapeables que pueden ser visualizados y analizados geográficamente. Una aplicación

típica de la georreferenciación en el ámbito de la logística sanitaria podría ser la localización precisa de hogares para servicios de atención médica a domicilio, optimizando rutas y tiempos de respuesta (Mayorga et al., 2022). La georreferenciación es crucial para la planificación y optimización de rutas en la logística, mejorando la eficiencia y reduciendo costos.

Machine Learning es un subcampo de la inteligencia artificial que involucra el desarrollo de algoritmos que permiten a las máquinas educarse y hacer pronósticos o tomar decisiones basadas en datos. Los algoritmos de machine learning mejoran automáticamente a través de la experiencia y el uso de los datos. En logística sanitaria, el machine learning puede ser utilizado para predecir demandas de servicio, identificar patrones de enfermedades, y optimizar la asignación de recursos y personal (Chatterjee et al., 2021). El Machine Learning proporciona herramientas avanzadas para analizar grandes volúmenes de datos y mejorar la toma de decisiones.

Modelos de Optimización son técnicas matemáticas utilizadas para encontrar las mejores soluciones de una variedad de posibles decisiones. La optimización busca maximizar o minimizar una función objetivo, por ejemplo, minimizar costos o maximizar la eficiencia, sujeta a un conjunto de restricciones. En la logística sanitaria, estos modelos pueden ayudar a planificar la distribución eficiente de recursos, diseñar rutas óptimas para la entrega de servicios y gestionar horarios del personal de manera eficiente ((Leefink et al., 2018). Los modelos de optimización permiten una utilización más efectiva de los recursos disponibles, mejorando la eficiencia operativa y reduciendo costos.

Marco Teórico

Existen investigaciones sobre ciencias de datos aplicadas a la logística de transporte terrestre. Estos estudios se centran en la optimización de rutas de entrega de mercancías (D. Liu et al., 2023), gestión de flotas (Elbert & Rentschler, 2022), y predicción de tiempos de tránsito (Delle et al., 2023), entre otros. Estas investigaciones, si bien valiosas, no abordan directamente las particularidades asociadas a la planeación logística de la prestación de servicios de atención médica domiciliaria, que incluyen la gestión de recursos humanos calificados, tiempo de atención, términos contractuales, capacidad instalada del personal médico, georreferenciación, equipos médicos, entre otras variables.

No obstante, las técnicas de ciencias de datos en la logística de transporte terrestre y modelos de optimización de rutas pueden proporcionar una base sólida para construir investigaciones específicas para esbozar estrategias logísticas aplicables a las atenciones médicas domiciliarias a partir de la ciencia de datos, que permitan mejorar la asignación de recursos y la eficiencia de las rutas, considerando las restricciones complejas y dinámicas de la prestación del servicio, asegurando que las atenciones médicas se realicen eficazmente y eficientemente.

Por tanto, si bien actualmente existe una brecha en la investigación específica sobre ciencias de datos aplicadas a la logística de atenciones médicas domiciliarias, los avances en campos relacionados ofrecen una oportunidad para plantear nuevas estrategias, con el potencial de generar un impacto significativo en la calidad y eficiencia de la atención médica domiciliaria.

En el entorno de la planificación de servicios de salud, se ha adoptado un enfoque similar al utilizado en la producción manufacturera. Una muestra de esto es el Plan Maestro de Admisión (PMA), que organiza la distribución de pacientes según Grupos Relacionados por el Diagnóstico (GRD) en intervalos diarios. Este enfoque toma en cuenta el flujo natural de las actividades en el hospital y su entorno dinámico (Braithwaite et al., 2017; Figueroa et al., 2019; Huebner & Flessa,

2022; Øygarden et al., 2020; Pomare et al., 2019). Este método se basa en los principios del sistema de planificación de recursos de manufactura (MRP II), ajustando la programación de recursos con estudios de sensibilidad de capacidad (CPR) (Kiran, 2019; Wang et al., 2023).

La implementación de MRP II en Instituciones Prestadoras de Salud tiene como objetivo desarrollar sistemas para planificar los recursos necesarios en la prestación de servicios domiciliarios, minimizar la variabilidad en el uso de recursos por GRD, y gestionar la capacidad desde las existencias hasta el personal médico y la asignación de citas (Kim & Hosni, 1998; Sum & Yang, 1993; Zäpfel, 1996).

A nivel nacional, Cuellar & Perez (2023), proponen una metodología basada en la simulación para determinar la capacidad de una clínica en Bogotá. Concluyen que la capacidad está subutilizada y recomiendan realizar más investigaciones sobre la gestión del personal.

Variables Planeación Atención Domiciliaria

En un esfuerzo por mejorar la planificación y entrega de servicios de salud a domicilio, esta investigación ha realizado una extensa revisión de la literatura, centrada en cómo la integración de tecnologías avanzadas puede transformar y optimizar la logística involucrada en la óptima asignación de recursos. Se han consultado bases de datos reconocidas como PubMed, Scopus, Web of Science e IEEE, seleccionadas específicamente por su amplia cobertura en el campo de la atención médica y la logística, así como en la ciencia de datos.

La estrategia de búsqueda empleada se basó en una combinación de términos clave altamente relevantes, tales como "Health Care Services at Home" en conjunción con "logistics", así como tecnologías disruptivas: "Machine Learning", "Big Data", "Deep Learning", "Neural Networks", "Genetic Algorithm", "Artificial Intelligence" y "Random Forest". Este enfoque aseguró la captura de artículos publicados entre 2014 y 2024, en idiomas inglés y español, que abordan directamente las variables relacionadas con la planificación logística del servicio domiciliario.

La amplitud de las temáticas identificadas refleja el alcance y la complejidad del tema. Se han distinguido enfoques robustos en la planificación de la capacidad de servicios de atención domiciliaria, técnicas de agrupamiento avanzadas para la programación del personal a gran escala, y sistemas de clasificación de pacientes que permiten una evaluación precisa. Estos sistemas son esenciales para asignar adecuadamente los recursos humanos en la atención de salud domiciliaria (Khallouli & Huang, 2022; Yinusa & Faezipour, 2023).

Además, la revisión ha subrayado la importancia de integrar la planificación a corto y largo plazo para garantizar la continuidad del cuidado y la eficiencia en las visitas domiciliarias. Las estrategias de planificación conjunta estocástica y los enfoques de descomposición anidada se han identificado como métodos eficaces para manejar la incertidumbre en la disponibilidad de

servicios y la demanda de cuidados de salud en el hogar (Errarhout et al., 2016). La planificación conjunta estocástica permite considerar múltiples escenarios de demanda y oferta, mientras que la descomposición anidada divide el problema en subproblemas más manejables, facilitando así una gestión más eficaz y adaptable de los recursos (Loftus et al., 2022).

En este contexto, el análisis de datos, la inteligencia artificial, el Machine Learning y la modelización computacional juegan un papel clave en la evolución de los servicios de atención domiciliaria. Estos enfoques permiten predecir demandas de servicio, identificar patrones de enfermedades y optimizar la asignación de recursos y personal. Por ejemplo, los algoritmos de aprendizaje profundo (Deep learning) se utilizan para analizar grandes volúmenes de datos y mejorar la precisión en la toma de decisiones, contribuyendo significativamente a mejorar la eficiencia y calidad del cuidado proporcionado al paciente (Yuan et al., 2023).

Resultados

Esta investigación se centra en el estudio de un conjunto de variables que impactan directamente en la planeación logística de la atención domiciliaria. Este análisis pormenorizado es crucial para diseñar sistemas que no solo respondan a las necesidades actuales, sino que también se anticipen y adapten a las futuras. En este contexto, la investigación realizada por Xie et al. (2023) ofrece una metodología de planificación de la capacidad de los servicios de atención domiciliaria atendiendo a un detallado conjunto de variables diseñadas para manejar la incertidumbre de la demanda.

El modelo de Xie et al. (2023) categoriza las variables en dos etapas: las de primera etapa, donde se toman decisiones proactivas sobre qué servicios se van a ofrecer y la cantidad de recursos que se van a asignar sin tener aún conocimiento de la demanda real; y las de segunda etapa, que involucran la asignación de recursos una vez que la demanda se ha hecho evidente. De

manera similar, Liu et al. (2021) y Fathollahi-Fard et al. (2022) abordan estas variables en sus modelos, que constituyen el esquema operativo que guiará la actuación una vez que la demanda real se presente.

En detalle, las variables consideradas en los estudios son:

La demanda proyectada de tipos de servicio en zonas específicas de clientes.

Las horas de servicio necesarias por tipo de personal para cada servicio.

Los ingresos generados por hora de servicio prestada, diferenciados por tipo de personal y zona de clientes.

El costo unitario resultante de no cumplir con las horas de servicio requeridas para cada tipo de personal en la zona de clientes.

El costo fijo asociado con la autorización para ofrecer cada tipo de servicio.

El costo fijo vinculado a la contratación de cada tipo de personal.

La capacidad máxima de horas de servicio que cada tipo de personal puede ofrecer.

El número mínimo de personal requerido para cada tipo de servicio.

La carga laboral máxima que puede asumir el personal de atención domiciliaria.

El tiempo productivo es el tiempo que los cuidadores dedican a realizar una tarea, es decir, realizar el trabajo real que se debe realizar.

El tiempo de viaje es el tiempo que los cuidadores dedican a viajar de un lugar a otro.

El tiempo inactivo es el tiempo que los cuidadores pasan simplemente esperando el inicio de una tarea, sin realizar ningún trabajo ni viajar.

El tiempo de trabajo es el tiempo que los cuidadores están trabajando para la empresa, tanto productivo como improductivo.

Estas variables son cruciales para diseñar modelos que permitan una asignación eficiente de recursos y una optimización efectiva de las rutas de atención. La incorporación de tecnologías

avanzadas como Machine Learning y algoritmos estocásticos en la modelización de estas variables ha demostrado ser esencial para mejorar la logística y eficiencia del cuidado de salud en el hogar. La validación y aplicación adecuada de estas variables clave continúa siendo un área fundamental para el desarrollo de sistemas de salud domiciliaria más adaptativos y eficientes.

La investigación actual ha resaltado la importancia de emplear algoritmos avanzados en la planificación estocástica, que incorpora variables aleatorias y modela la incertidumbre. Esto resalta el potencial de combinar métodos heurísticos y técnicas de optimización matemática para superar los desafíos asociados con la atención de salud en el hogar. Los algoritmos estocásticos permiten manejar mejor la variabilidad y la incertidumbre en la demanda y la disponibilidad de recursos, lo cual es crucial para la eficiencia en la logística sanitaria (Loftus et al., 2022).

Para finalizar, Nikzad et al. (2021) realizaron un estudio en el que desarrollan un modelo para la planificación de recursos humanos en el contexto del cuidado de la salud a domicilio. Este modelo se enfoca en una serie de variables críticas que inciden directamente en la eficiencia y eficacia del servicio de atención domiciliaria. Dentro de estas variables, los autores incluyen decisiones tácticas y estratégicas que abarcan la zonificación, el dimensionamiento del personal, la asignación de recursos, la programación y la ruta del personal de atención a domicilio, en modelos similares. La modelización propuesta toma en cuenta la incertidumbre inherente a los tiempos de servicio y de viaje, incorporándola en su análisis estocástico. En este contexto, las decisiones de zonificación y dimensionamiento del personal se consideran en la primera etapa del modelo, mientras que la asignación, la programación y la ruta se manejan en la segunda etapa. Para resolver este modelo complejo, los autores proponen un algoritmo metaheurístico (Nikzad et al., 2021).

Aplicación de la Ciencia de Datos a Logística Sanitaria

Tras la revisión de la literatura y el análisis de documentos, se pueden identificar múltiples aplicaciones de la ciencia de datos en la planificación logística de servicios domiciliarios de salud y la logística en transporte terrestre. Es fundamental para asegurar una atención eficiente. Algoritmos avanzados pueden calcular las rutas más cortas y rápidas, considerando factores como el tráfico y las condiciones del camino. Esto no solo reduce los tiempos de viaje y costos operativos, sino que también mejora la puntualidad y calidad del servicio ofrecido a los pacientes (Huebner & Flessa, 2022).

En la Tabla 1 se presenta una matriz de correspondencia de técnicas de Machine Learning y variables en investigaciones sobre planificación de atención médica domiciliaria.

Tabla 1

Matriz de Correspondencia de Técnicas de Machine Learning y Variables en Investigaciones sobre Planificación de Atención Médica Domiciliaria.

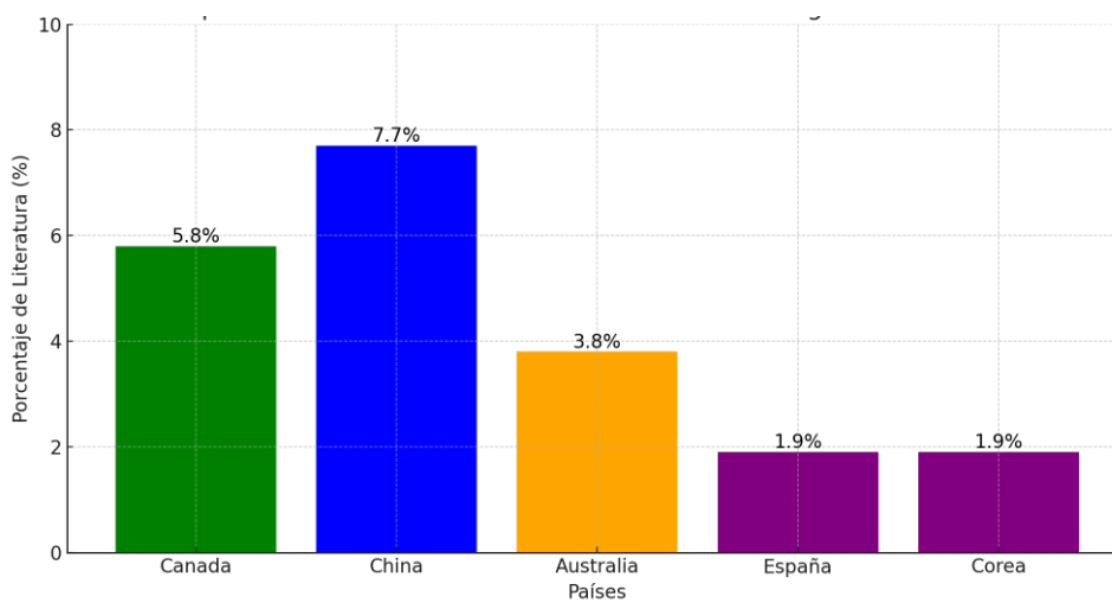
	Descripción	Talento Humano	Rutas	Tráfico de Vehículos	Capacidad instalada	Total	Porcentaje
	Logistic Regression	1				1	1,9%
	KNN - K-Nearest Neighbors	1	1	1		3	5,8%
Técnica de	LSTM - Long Short-Term Memory		4	1		5	9,6%
Machine	Neural Networks		4	2		6	11,5%
Learning	Decision Trees		1			1	1,9%
	SVM - Support Vector Machines		3	1		4	7,7%
	RNN - Recurrent Neural Networks		1	1		2	3,8%
Modelos de	Programación No Lineal (PNL)		1			1	1,9%
optimización	Optimización Estocástica:		2			2	3,8%
	Optimización Multiobjetivo		3			3	5,8%
Idioma	Español					0	0,0%
	Ingles	1				1	1,9%
	Artículo	2	2	1		5	9,6%
Tipo de	Conferencias		4	1		5	9,6%
escrito	Short survey		1			1	1,9%
	Tesis					0	0,0%
	Review			1		1	1,9%
	Libro					0	0,0%
País	Colombia					0	0,0%
	Noruega					0	0,0%

Descripción	Talento Humano	Rutas	Tráfico de Vehículos	Capacidad instalada	Total	Porcentaje
Canadá		2	1		3	5,8%
China		3	1		4	7,7%
Australia		1	1		2	3,8%
Japón					0	0,0%
España	1				1	1,9%
Corea	1				1	1,9%
India					0	0,0%

Nota. Esta tabla muestra la relación de la validación bibliográfica realizada.

Figura 1

Aplicación de Técnicas de Ciencia de Datos en Logística Sanitaria.



Fuente. Elaboración propia

La Figura 1 ilustra la aplicación de técnicas de ciencia de datos en la logística sanitaria desde una perspectiva global, observamos que países como China y Canadá están a la vanguardia en la aplicación de estas técnicas, con un 7.7% y 5.8% de la literatura respectivamente. Esto

puede reflejar una mayor adopción de estrategias basadas en datos en sus sistemas de salud o un mayor enfoque en la investigación en ciencia de datos aplicada a la logística.

Esta matriz de correspondencia en la Tabla 1 presenta una síntesis de las técnicas de Machine Learning aplicadas en el ámbito de la atención médica domiciliaria, categorizadas según el idioma del estudio, el tipo de documento, y el país de origen. Cada celda refleja el número de estudios que combinan estas dimensiones, destacando la prevalencia de ciertas técnicas y enfoques en diferentes contextos. Esta tabla facilita la identificación de las tendencias predominantes y las áreas menos exploradas en la literatura, ofreciendo una herramienta valiosa para futuras investigaciones.

Al realizar un análisis estadístico de las investigaciones previas, se observa que las Redes Neuronales son la técnica de Machine Learning más prevalente, utilizadas en el 11.5% de los estudios relacionados con la planificación logística. Esto subraya su versatilidad y capacidad para modelar complejas relaciones no lineales en datos de salud y logística (Albawi et al., 2017). Por ejemplo, las redes neuronales han sido aplicadas para predecir rutas y tráfico de vehículos, dos factores claves en la planificación logística sanitaria.

Por otro lado, las Redes Neuronales Recurrentes (RNN), que tienen un uso del 9.6%, son especialmente útiles para capturar dependencias temporales en datos de series temporales (Hewamalage et al., 2021). Esto es particularmente relevante en la logística sanitaria, donde la demanda de servicios y la disponibilidad de recursos pueden variar significativamente a lo largo del tiempo.

Las Máquinas de Soporte Vectorial (SVM), con un 7.7% de presencia en los estudios revisados, y los K-Nearest Neighbors (KNN), con un 5.8%, demuestran ser herramientas sólidas en el análisis predictivo y clasificación, respectivamente (Roudak et al., 2024). Ambas técnicas ofrecen enfoques distintos para abordar problemas de logística sanitaria.

En el campo del talento humano se cuenta con ML de Logistic Regression (Figuroa et al., 2019). Curiosamente, la Optimización Multiobjetivo se señala en el 5.8% de los casos, destacando la importancia de equilibrar múltiples metas en la planificación de recursos (Jayarathna et al., 2021). En su estudio, Jayarathna et al. (2021) utilizan algoritmos de optimización multiobjetivo para equilibrar la minimización de costos y el tiempo de respuesta en la entrega de servicios. Esto implica la utilización de técnicas como la programación lineal y metaheurísticas avanzadas para encontrar soluciones que satisfagan varias restricciones simultáneamente, mejorando tanto la eficiencia operativa como la calidad del servicio.

Estas aplicaciones prácticas demuestran cómo las SVM, KNN y técnicas de optimización multiobjetivo pueden ser integradas en la logística sanitaria para mejorar la planificación y ejecución de los servicios, optimizando el uso de recursos y mejorando la atención al paciente.

Este análisis establece una base sólida para entender cómo los métodos avanzados de ciencia de datos pueden ser aplicados efectivamente en la logística sanitaria. En este contexto, la planificación de servicios de atención médica domiciliaria se enfrenta a retos significativos debido a la incertidumbre en la demanda y la asignación de recursos. Errarhout et al. (2016) han propuesto un modelo estocástico de dos etapas que permite una planificación conjunta de la autorización de servicios y la capacidad. Este modelo no solo considera las variables críticas de la demanda y la autorización de servicios, sino que también maximiza los ingresos totales esperados, proveyendo un marco sólido para decisiones estratégicas en la atención domiciliaria.

Para abordar el modelo estocástico de planificación de servicios, los autores introducen un algoritmo de descomposición anidada basado en supergradiente, que se adapta eficientemente a la estructura del problema, permitiendo encontrar soluciones óptimas en problemas de gran tamaño (Errarhout et al., 2016). Extendiendo el modelo de planificación a un enfoque más general, los investigadores aplican el criterio de Valor en Riesgo Condicional para evaluar el riesgo en la

toma de decisiones. El modelo reformulado en esta investigación permite la integración de la gestión de riesgos en la planificación, lo que es crucial para el desarrollo de una logística sanitaria resiliente y adaptable, especialmente en escenarios donde la variabilidad de la demanda puede tener impactos significativos en los resultados operativos y financieros (Errarhout et al., 2016).

Con estos métodos avanzados, la logística sanitaria puede experimentar mejoras sustanciales en la asignación de recursos y en la gestión de la incertidumbre. La incorporación de modelos estocásticos y algoritmos de optimización destaca el potencial de la ciencia de datos para revolucionar la atención médica domiciliaria, favoreciendo así un modelo más sostenible y centrado en el paciente que responde a las dinámicas actuales del sector de la salud.

Belle et al. (2015) exploran cómo los modelos estocásticos pueden ser utilizados para gestionar la variabilidad y la incertidumbre en la demanda de servicios de salud domiciliarios. Su investigación demuestra que la planificación basada en estos modelos permite una asignación más eficiente de los recursos, lo que reduce los tiempos de espera y mejora la calidad del servicio.

Ageron et al. (2018) se centran en la aplicación de algoritmos de optimización en la logística sanitaria. Su estudio muestra cómo estos algoritmos pueden optimizar rutas y horarios para el personal de salud, minimizando los costos operativos y maximizando la cobertura y eficiencia del servicio. Además, destacan la importancia de integrar datos en tiempo real para ajustar las operaciones logísticas según las necesidades cambiantes.

Estas investigaciones subrayan el impacto positivo de la ciencia de datos en la logística sanitaria, proporcionando soluciones innovadoras que mejoran tanto la eficiencia operativa como la experiencia del paciente.

Estrategias de Distribución de Recursos a partir de Modelos de Machine Learning

Introducción

La investigación en ciencias de datos, que incluye el análisis de grandes volúmenes de datos y el desarrollo de algoritmos avanzados como Machine Learning, Redes Neuronales y Deep Learning, ha revolucionado varios sectores económicos, incluida la salud. Sin embargo, la logística de rutas para atenciones médicas domiciliarias presenta desafíos únicos debido a su necesidad de adaptación a condiciones cambiantes en tiempo real y optimización de rutas con múltiples restricciones.

Identificación de Variables Clave para Colombia

Para implementar una estrategia efectiva de machine learning en la logística de atención médica domiciliaria en Colombia, es esencial identificar las variables más adecuadas.

Basándonos en la literatura y las características del sistema de salud colombiano, las siguientes variables son cruciales:

Demanda de servicios médicos: Frecuencia y tipo de servicios solicitados.

Ubicación de pacientes y personal médico: Coordenadas geográficas para optimización de rutas.

Disponibilidad de recursos: Inventarios de medicamentos y equipos médicos.

Condiciones del tráfico y rutas: Datos en tiempo real y patrones históricos de tráfico.

Condiciones climáticas: Impacto en la movilidad y accesibilidad.

Historial médico de pacientes: Información relevante para priorización y asignación de recursos.

Estrategia Propuesta para el Uso de Machine Learning

Etapa 1: Análisis Predictivo

En la primera etapa, utilizaremos modelos predictivos para anticipar la demanda de servicios y optimizar la asignación de recursos. Según Thompson et al. (2022), los modelos de machine learning como las Redes Neuronales y los Algoritmos de Árboles de Decisión son altamente efectivos para predecir patrones de demanda basándose en datos históricos.

Modelos Propuestos.

Redes Neuronales Artificiales (ANN). Por su capacidad para manejar relaciones no lineales y complejas en grandes conjuntos de datos.

Bosques Aleatorios (Random Forest). Por su precisión y capacidad para manejar grandes cantidades de variables de entrada.

Justificación del Modelo.

El modelo de Redes Neuronales Artificiales (ANN) se selecciona debido a su alta precisión en la predicción de demanda y su capacidad para aprender patrones complejos de los datos históricos de pacientes y servicios. Estudios como los de Zhang et al. (2019) y Li et al. (2020) han demostrado que las ANN son altamente efectivas para modelar y predecir la demanda en contextos de salud, superando a otros métodos tradicionales en términos de precisión y adaptabilidad. Además, investigaciones realizadas por Kumar y Rathore (2021) destacan que las ANN pueden manejar grandes volúmenes de datos con múltiples variables, lo que las hace particularmente adecuadas para aplicaciones en la logística sanitaria donde la complejidad y la variabilidad de los datos son significativas.

Etapa 2: Optimización de Rutas y Recursos

En la segunda etapa, se aplicarán algoritmos de optimización para mejorar la eficiencia en la logística de atención domiciliaria. Los estudios de Chen et al. (2024) muestran que las Redes Neuronales Convolucionales (CNN) pueden ser utilizadas para analizar patrones de tráfico en tiempo real y ajustar las rutas de manera dinámica.

Modelos Propuestos.

Redes Neuronales Convolucionales (CNN). Para el análisis en tiempo real de patrones de tráfico.

Algoritmos Genéticos. Para la optimización de rutas bajo múltiples restricciones.

Justificación del Modelo.

El uso de Algoritmos Genéticos se justifica por su capacidad para encontrar soluciones óptimas en problemas complejos de optimización, como la planificación de rutas con múltiples restricciones (distancia, tiempo, tráfico, etc.).

Implementación y Evaluación

Recolección y Preprocesamiento de Datos. Integrar datos de múltiples fuentes (historial médico, tráfico, clima).

Entrenamiento de Modelos. Utilizar conjuntos de datos históricos para entrenar los modelos predictivos y de optimización.

Implementación Piloto. Desplegar los modelos en un entorno controlado para evaluar su rendimiento.

Monitoreo y Ajustes. Monitorear el desempeño en tiempo real y realizar ajustes necesarios.

Indicadores de Éxito:

Precisión en la Predicción de Demanda. Evaluada mediante métricas como MAE y RMSE.

Eficiencia en la Optimización de Rutas. Medida por la reducción en tiempos de viaje y costos operativos.

Satisfacción del Paciente. Evaluada mediante encuestas y feedback.

Conclusiones

La identificación de variables como la frecuencia de servicios solicitados, la localización geográfica de pacientes y personal, la disponibilidad de recursos médicos, y las condiciones del tráfico y clima ha proporcionado una base sólida para entender las dinámicas de la atención domiciliaria. Estas variables son esenciales para diseñar estrategias logísticas efectivas que garanticen una atención eficiente y de alta calidad para los pacientes.

La demanda de servicios médicos domiciliarios está influenciada por factores como la prevalencia de enfermedades crónicas, la edad de la población, y las políticas de salud pública. Conocer la frecuencia y tipo de servicios solicitados permite anticipar necesidades y planificar de manera proactiva. La localización geográfica de pacientes y personal es crucial para la optimización de rutas y la minimización de tiempos de viaje, lo cual no solo reduce costos operativos, sino que también mejora la puntualidad del servicio.

Además, la disponibilidad de recursos médicos, incluyendo medicamentos y equipos, y su adecuada gestión son fundamentales para asegurar que los pacientes reciban la atención necesaria sin demoras. Las condiciones del tráfico y clima afectan significativamente la movilidad y accesibilidad, lo cual debe ser considerado en la planificación de rutas y en la asignación de tiempo para cada visita domiciliaria.

El análisis de estas variables a través de técnicas de ciencia de datos permite no solo una mejor comprensión de las necesidades actuales sino también la capacidad de predecir demandas futuras y ajustar las operaciones en consecuencia, mejorando así la eficiencia y calidad de los servicios de atención domiciliaria.

La revisión de la literatura y el análisis de estudios de caso han demostrado de manera concluyente que la integración de técnicas avanzadas de Machine Learning en la logística sanitaria puede optimizar significativamente la planificación de rutas y la asignación de recursos.

Específicamente, los modelos predictivos como las Redes Neuronales Artificiales (ANN) y los Algoritmos de Árboles de Decisión (Decision Trees) se han destacado por su capacidad para predecir patrones de demanda con alta precisión. Estos modelos utilizan datos históricos para identificar tendencias y prever necesidades futuras, lo que permite una asignación más precisa y eficiente de los recursos humanos y materiales.

Además, los algoritmos de optimización, como los Algoritmos Genéticos y las Redes Neuronales Convolucionales (CNN), han demostrado ser efectivos en mejorar la eficiencia logística al analizar patrones de tráfico en tiempo real y ajustar dinámicamente las rutas de los profesionales de salud. Estos algoritmos no solo consideran la distancia y el tiempo de viaje, sino también factores como el tráfico, las condiciones climáticas y la disponibilidad de recursos en cada momento. Esto resulta en rutas más cortas y tiempos de respuesta más rápidos, mejorando la puntualidad y la calidad del servicio ofrecido a los pacientes.

La implementación de Machine Learning también facilita la gestión de la incertidumbre y la variabilidad en la demanda de servicios. Los modelos estocásticos y de optimización multiobjetivo permiten equilibrar múltiples objetivos, como minimizar costos operativos y maximizar la cobertura y eficiencia del servicio. Estos modelos pueden adaptarse a cambios en la demanda y en la disponibilidad de recursos, proporcionando una solución flexible y robusta para la planificación logística.

En el contexto de Clínicos IPS en Bogotá, la adopción de estas tecnologías promete transformar la logística sanitaria, permitiendo una distribución más equitativa y eficiente de los recursos. Esto no solo mejorará la eficiencia operativa y la calidad del servicio, sino que también puede reducir el estrés y la carga de trabajo del personal de salud, mejorando su satisfacción laboral y reduciendo la rotación de personal.

La implementación de tecnologías avanzadas como el Machine Learning en Clínicos IPS en Bogotá promete no solo mejorar la eficiencia operativa y la calidad del servicio sino también transformar fundamentalmente la logística sanitaria. Los beneficios incluyen una distribución más equitativa y eficiente de los recursos, tiempos de respuesta más rápidos, y una mayor precisión en la asignación de recursos, lo que en última instancia se traduce en una mejor atención al paciente.

Sin embargo, la implementación de estas tecnologías presenta varios desafíos que deben ser abordados para garantizar su éxito. Uno de los principales desafíos es la calidad y disponibilidad de los datos. Para que los modelos de Machine Learning sean efectivos, se requiere un gran volumen de datos precisos y actualizados. Esto implica la necesidad de sistemas robustos de recolección y gestión de datos, así como la capacitación del personal en el manejo y análisis de estos datos.

Otro desafío es la integración de nuevas tecnologías con los sistemas de salud existentes. La compatibilidad y la interoperabilidad entre diferentes sistemas y plataformas son cruciales para asegurar una implementación sin problemas. Además, es necesario invertir en la formación continua del personal para que puedan utilizar eficazmente estas nuevas tecnologías.

Además, existen consideraciones éticas y de privacidad relacionadas con el manejo de datos de pacientes. Es crucial establecer políticas de manejo y protección de datos que aseguren la privacidad y seguridad de la información de los pacientes, cumpliendo con las normativas locales e internacionales.

Para abordar estos desafíos, se recomienda que Clínicos IPS invierta en la mejora de su infraestructura tecnológica, en la capacitación continua de su personal, y en la colaboración con instituciones académicas y de investigación para mantenerse a la vanguardia en el uso de estas tecnologías. Asimismo, es fundamental establecer un marco regulatorio y ético sólido que guíe la

implementación y uso de estas tecnologías, asegurando que se respeten los derechos y la privacidad de los pacientes.

Referencias Bibliográficas

- Ageron, B., Benzidia, S., & Bourlakis, M. (2018). Healthcare logistics and supply chain – issues and future challenges. *Supply Chain Forum: An International Journal*, 19(1), 1–3. <https://doi.org/10.1080/16258312.2018.1433353>
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017*, 2018-January, 1–6. <https://doi.org/10.1109/ICENGTECHNOL.2017.8308186>
- Belle, A., Thiagarajan, R., Soroushmehr, S. M. R., Navidi, F., Beard, D. A., & Najarian, K. (2015). Big Data Analytics in Healthcare. *BioMed Research International*, 2015. <https://doi.org/10.1155/2015/370194>
- Braithwaite, J., Herkes, J., Ludlow, K., Testa, L., & Lamprell, G. (2017). Association between organisational and workplace cultures, and patient outcomes: systematic review. *BMJ Open*, 7(11). <https://doi.org/10.1136/BMJOPEN-2017-017708>
- Brown, P. A., & Anderson, R. A. (2023). A methodology for preprocessing structured big data in the behavioral sciences. *Behavior Research Methods*, 55(4). <https://doi.org/10.3758/s13428-022-01895-4>
- Bustamante, J. P., Puertas, E. B., Hernández Hernández, D., & Sepúlveda, H. (2023). COVID-19 and human resources for health: analysis of planning, policy responses and actions in Latin American and Caribbean countries. *Human Resources for Health*, 21(1), 1–19. <https://doi.org/10.1186/S12960-023-00795-8/TABLES/6>
- Chatterjee, S., Goyal, D., Prakash, A., & Sharma, J. (2021). Exploring healthcare/health-product ecommerce satisfaction: A text mining and machine learning application. *Journal of Business Research*, 131. <https://doi.org/10.1016/j.jbusres.2020.10.043>

- Chen, Y., Yin, X., Zhang, R., & Gao, F. (2024). Reinforced convolutional neural network fault diagnosis of industrial production systems. *Chemical Engineering Science*, 299, 120466. <https://doi.org/10.1016/J.CES.2024.120466>
- Cuellar, Y., & Perez, L. (2023). Multitemporal modeling and simulation of the complex dynamics in urban wetlands: the case of Bogota, Colombia. *Scientific Reports* 2023 13:1, 13(1), 1–18. <https://doi.org/10.1038/s41598-023-36600-8>
- Delle, D., Alfandari, L., Archetti, C., & Ljubić, I. (2023). Freight-on-Transit for urban last-mile deliveries: A strategic planning approach. *Transportation Research Part B: Methodological*, 169, 53–81. <https://doi.org/10.1016/J.TRB.2023.01.004>
- Dirección de Desarrollo del Talento Humano en Salud. (2018). *Política Nacional de Talento Humano en Salud*. MinSalud.
- Elbert, R., & Rentschler, J. (2022). Freight on urban public transportation: A systematic literature review. *Research in Transportation Business & Management*, 45, 100679. <https://doi.org/10.1016/J.RTBM.2021.100679>
- Errorhout, A., Kharraja, S., & Corbier, C. (2016). Two-stage Stochastic Assignment Problem in the Home Health Care. *IFAC-PapersOnLine*, 49(12), 1152–1157. <https://doi.org/10.1016/J.IFACOL.2016.07.659>
- Fathollahi-Fard, A. M., Ahmadi, A., & Karimi, B. (2022). Sustainable and Robust Home Healthcare Logistics: A Response to the COVID-19 Pandemic. *Symmetry*, 14(2), 193. <https://doi.org/10.3390/SYM14020193/S1>
- Figuroa, C. A., Harrison, R., Chauhan, A., & Meyer, L. (2019). Priorities and challenges for health leadership and workforce management globally: A rapid review. *BMC Health Services Research*, 19(1), 1–11. <https://doi.org/10.1186/S12913-019-4080-7/TABLES/3>

- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388–427. <https://doi.org/10.1016/J.IJFORECAST.2020.06.008>
- Huebner, C., & Flessa, S. (2022). Strategic Management in Healthcare: A Call for Long-Term and Systems-Thinking in an Uncertain System. *International Journal of Environmental Research and Public Health*, 19(14). <https://doi.org/10.3390/IJERPH19148617>
- Jayarathna, C. P., Agdas, D., Dawes, L., & Yigitcanlar, T. (2021). Multi-objective optimization for sustainable supply chain and logistics: A review. *Sustainability (Switzerland)*, 13(24), 13617. <https://doi.org/10.3390/SU132413617/S1>
- Khallouli, W., & Huang, J. (2022). Cluster resource scheduling in cloud computing: literature review and research challenges. *Journal of Supercomputing*, 78(5), 6898–6943. <https://doi.org/10.1007/S11227-021-04138-Z/METRICS>
- Kim, H. J., & Hosni, Y. A. (1998). Manufacturing lot-sizing under MRP II environment: An improved analytical model & heuristic procedure. *Computers & Industrial Engineering*, 35(3–4), 423–426. [https://doi.org/10.1016/S0360-8352\(98\)00124-7](https://doi.org/10.1016/S0360-8352(98)00124-7)
- Kiran, D. R. (2019). Manufacturing resource planning (MRP II). In *Production Planning and Control* (pp. 441–455). Butterworth-Heinemann. <https://doi.org/10.1016/B978-0-12-818364-9.00031-7>
- Leefink, A. G., Bikker, I. A., Vliegen, I. M. H., & Boucherie, R. J. (2018). Multi-disciplinary planning in health care: a review. *Health Systems (Basingstoke, England)*, 9(2), 95–118. <https://doi.org/10.1080/20476965.2018.1436909>

- Liu, D., Hu, X., & Jiang, Q. (2023). Design and optimization of logistics distribution route based on improved ant colony algorithm. *Optik*, 273, 170405.
<https://doi.org/10.1016/J.IJLEO.2022.170405>
- Liu, W., Dridi, M., Fei, H., & El Hassani, A. H. (2021). Hybrid metaheuristics for solving a home health care routing and scheduling problem with time windows, synchronized visits and lunch breaks. *Expert Systems with Applications*, 183, 115307.
<https://doi.org/10.1016/J.ESWA.2021.115307>
- Loftus, T. J., Tighe, P. J., Ozrazgat-Baslanti, T., Davis, J. P., Ruppert, M. M., Ren, Y., Shickel, B., Kamaleswaran, R., Hogan, W. R., Moorman, J. R., Gilbert R. Upchurch, J., Rashidi, P., & Bihorac, A. (2022). Ideal algorithms in healthcare: Explainable, dynamic, precise, autonomous, fair, and reproducible. *PLOS Digital Health*, 1(1), e0000006. <https://doi.org/10.1371/JOURNAL.PDIG.0000006>
- Mayorga, A., Hugo, M., & Uvidia, M. (2022). Sistemas de información geográfica aplicados a la topografía. *Opuntia Brava*, 11(4).
- Möckli, N., Simon, M., Meyer-Masseti, C., Pihet, S., Fischer, R., Wächter, M., Serdaly, C., & Zúñiga, F. (2021). Factors associated with homecare coordination and quality of care: a research protocol for a national multi-center cross-sectional study. *BMC Health Services Research*, 21(1). <https://doi.org/10.1186/S12913-021-06294-7>
- Nikzad, E., Bashiri, M., & Abbasi, B. (2021). A matheuristic algorithm for stochastic home health care planning. *European Journal of Operational Research*, 288(3), 753–774.
<https://doi.org/10.1016/J.EJOR.2020.06.040>
- Organización Panamericana de la Salud. (2023, April 3). V Foro Global de Recursos Humanos para la Salud - OPS/OMS. OPS. <https://www.paho.org/es/eventos/v-foro-global-recursos-humanos-para-salud>

- Øygarden, O., Olsen, E., & Mikkelsen, A. (2020). Changing to improve? Organizational change and change-oriented leadership in hospitals. *Journal of Health Organization and Management*, 34(6), 687. <https://doi.org/10.1108/JHOM-09-2019-0280>
- Pomare, C., Churruca, K., Long, J. C., Ellis, L. A., & Braithwaite, J. (2019). Organisational change in hospitals: A qualitative case-study of staff perspectives. *BMC Health Services Research*, 19(1), 1–9. <https://doi.org/10.1186/S12913-019-4704-Y/TABLES/2>
- Qin, X., Huang, Y. N., Hu, Z., Chen, K., Li, L., Wang, R. S., & Wang, B. L. (2023). Human resource management research in healthcare: a big data bibliometric study. *Human Resources for Health*, 21(1), 1–11. <https://doi.org/10.1186/S12960-023-00865-X/FIGURES/5>
- Resolución 3100. (2019, November 25). Por la cual se definen los procedimientos y condiciones de inscripción de los prestadores de servicios de salud y de habilitación de IOS servicios de salud y se adopta el Manual de Inscripción de Prestadores y Habilitación de Servicios de Salud. Ministerio de Salud y Protección Social. (Colombia). Obtenido El 19 de Agosto de 2024.
https://www.minsalud.gov.co/Normatividad_Nuevo/Resoluci%C3%B3n%20No.%203100%20de%202019.pdf
- Roudak, M. A., Farahani, M., & Hosseinbeigi, F. B. (2024). Extension of K-nearest neighbors and introduction of an applicable prediction criterion for a novel Monte Carlo simulation-based method in structural reliability. *Structures*, 66, 106867. <https://doi.org/10.1016/J.ISTRUC.2024.106867>

- Sabetkish, N., & Rahmani, A. (2021). The overall impact of COVID-19 on healthcare during the pandemic: A multidisciplinary point of view. *Health Science Reports*, 4(4). <https://doi.org/10.1002/HSR2.386>
- Secretaría de Salud. (2021). Análisis de oferta y demanda de servicios de salud. Alcaldía Mayor de Bogota .
- Sum, C. C., & Yang, K. K. (1993). A study on manufacturing resource planning (MRP II) practices in Singapore. *Omega*, 21(2), 187–197. [https://doi.org/10.1016/0305-0483\(93\)90051-L](https://doi.org/10.1016/0305-0483(93)90051-L)
- Wang, Z. X., Jv, Y. Q., Wang, Z. D., & Ma, J. H. (2023). Coordination estimation of enterprise resource planning and manufacturing execution system diffusion in China's manufacturing industry: A panel Lotka-Volterra method. *Computers & Industrial Engineering*, 176, 108923. <https://doi.org/10.1016/J.CIE.2022.108923>
- Xie, W., Liu, T., Li, X., & Zheng, C. (2023). Robust homecare service capacity planning. *Computers & Operations Research*, 154, 106155. <https://doi.org/10.1016/J.COR.2023.106155>
- Yalçındağ, S., & Lanzarone, E. (2022). Merging short-term and long-term planning problems in home health care under continuity of care and patterns for visits. *Journal of Industrial and Management Optimization*, 18(2), 1487–1504. <https://doi.org/10.3934/JIMO.2021029>
- Yinusa, A., & Faezipour, M. (2023). Optimizing Healthcare Delivery: A Model for Staffing, Patient Assignment, and Resource Allocation. *Applied System Innovation* 2023, Vol. 6, Page 78, 6(5), 78. <https://doi.org/10.3390/ASI6050078>

Yoshizaki, H. T. Y. (2018). Supply Chain Management and Logistics in Latin America (H.

T. Y. Yoshizaki, J. C. Velázquez Martínez, & C. M. Argueta, Eds.). Emerald

Publishing Limited. <https://doi.org/10.1108/9781787568037>

Yuan, Z., Wang, Z., Li, X., Li, L., & Zhang, L. (2023). Hierarchical Trajectory Planning for

Narrow-Space Automated Parking with Deep Reinforcement Learning: A Federated

Learning Scheme. *Sensors*, 23(8). <https://doi.org/10.3390/s23084087>

Zäpfel, G. (1996). Production planning in the case of uncertain individual demand Extension

for an MRP II concept. *International Journal of Production Economics*, 46–47, 153–

164. [https://doi.org/10.1016/0925-5273\(95\)00192-1](https://doi.org/10.1016/0925-5273(95)00192-1)

Apéndice

Apéndice A

Glosario

Algoritmos Genéticos: Técnicas de optimización suscitadas en la evolución natural, que utilizan procesos como selección, cruzamiento y transformación para encontrar soluciones magníficas en problemas complejos.

Atención Médica Domiciliaria (HHC): Provisión de servicios médicos a pacientes en sus hogares en lugar de en centros de salud tradicionales, facilitando cuidados personalizados y reduciendo la necesidad de hospitalización.

Big Data: Conjuntos de datos considerablemente grandes y complejos que necesitan tecnologías avanzadas de almacenamiento, procesamiento y análisis para extraer información útil. En salud, se utiliza para perfeccionar la toma de decisiones fundada en datos.

Bosques Aleatorios (Random Forest): Algoritmo de Machine Learning que utiliza múltiples árboles de decisión para mejorar la precisión de las predicciones y manejar grandes conjuntos de datos con muchas variables.

Ciencia de Datos: Campo interdisciplinario que maneja métodos científicos, procesos, algoritmos y sistemas para extraer conocimiento e información de datos estructurados y no estructurados. Implica la producción, procesamiento, análisis e interpretación de datos.

Condiciones Climáticas: Variables meteorológicas que afectan la movilidad y accesibilidad en la logística sanitaria, importantes para la planificación de rutas y la asignación de recursos en servicios de atención domiciliaria.

Condiciones del Tráfico: Datos en tiempo real y patrones históricos de tráfico que influyen en la planificación y optimización de rutas en la logística sanitaria.

Deep Learning: Es una rama del aprendizaje automático que se basa en el uso de redes neuronales profundas, las cuales consisten en múltiples capas. Estas redes son capaces de modelar y resolver problemas complejos. Se destacan por su eficacia en el reconocimiento de patrones y en el procesamiento de grandes cantidades de datos.

Georreferenciación: Proceso de asignar información espacial a datos, permitiendo la representación de estos en un mapa geográfico. Es esencial para optimizar rutas y tiempos de respuesta en la logística sanitaria.

Logística Sanitaria: Coordinación eficiente de recursos médicos, como medicamentos, equipos y suministros, desde la adquisición hasta la distribución y almacenamiento, para asegurar la accesibilidad y eficiencia de los servicios de salud.

Machine Learning: Subcampo de la inteligencia artificial que desarrolla algoritmos que permiten a las máquinas aprender de datos y hacer predicciones o decisiones basadas en ellos. Mejora automáticamente con la experiencia.

Modelos de Optimización: Técnicas matemáticas utilizadas para encontrar las mejores soluciones entre varias posibles decisiones, maximizando o minimizando una función objetivo bajo ciertas restricciones. En logística sanitaria, ayudan a planificar la distribución eficiente de recursos y diseñar rutas óptimas.

Modelos Predictivos: Algoritmos que utilizan datos históricos para predecir futuras demandas de servicios y optimizar la asignación de recursos. Son fundamentales para la planificación estratégica en la atención domiciliaria.

Optimización Estocástica: Método que incorpora variables aleatorias y modela la incertidumbre en los procesos de optimización, permitiendo manejar la variabilidad en la demanda y la disponibilidad de recursos en la logística sanitaria.

Programación Lineal: Técnica de optimización matemática para maximizar o minimizar una función lineal sujeta a restricciones lineales. Utilizada en logística para resolver problemas de asignación y planificación.

Recursos Humanos de Salud (RHS): Personal necesario para proporcionar servicios de salud, incluyendo médicos, enfermeras, técnicos y otros profesionales de la salud. Su adecuada gestión y distribución son cruciales para el funcionamiento eficiente del sistema de salud.

Redes Neuronales: Algoritmos inspirados en la estructura y funcionamiento del cerebro humano, utilizados en Machine Learning para modelar relaciones complejas en los datos. Son eficaces para tareas como el reconocimiento de patrones y la predicción.

Técnicas Heurísticas: Métodos de solución de problemas que utilizan reglas empíricas para encontrar soluciones aproximadas cuando las técnicas exactas son impracticables. Son útiles en la optimización de rutas y la asignación de recursos en logística sanitaria.