

INTELIGENCIA ARTIFICIAL PARA LA ASIGNACIÓN ÓPTIMA DE MÉDICOS ESPECIALISTAS EN LA ADMINISTRACIÓN DEL SERVICIO DE GERIATRÍA

ARTIFICIAL INTELLIGENCE FOR OPTIMAL ALLOCATION OF SPECIALIST PHYSICIANS GERIATRICS SERVICE MANAGEMENT

Gustavo Silva Rodríguez¹
Alexandra Abuchar Porras²
Roberto Ferro Escobar³

Resumen

El presente artículo, está centrado en una implementación para la asignación de personal médico especializado para el servicio de geriatría, que administrativamente se realiza de forma manual, de acuerdo con un modelado de una Red Neuronal que incorpora el comportamiento epidemiológico de la demanda, la disposición de la capacidad instalada, horarios disponibles de los profesionales, tipos de vinculación, lugares geográficos donde presta la atención. La metodología empleada abarca el proceso de recopilación de datos médicos, los cuales son sometidos a algoritmos de aprendizaje automático, que permiten la validación clínica y evaluación comparativa con estándares convencionales. El enfoque metodológico utilizado, evidencia que las estrategias de adquisición y procesamiento de datos, el diseño experimental y las técnicas de evaluación, garantizan una plausible precisión, fiabilidad y aplicabilidad de los modelos de IA, por la maximización arrojada por el algoritmo de ramificación y acotamiento, en el contexto médico de la administración del servicio de Geriatría.

Palabras clave: Inteligencia Artificial en Medicina, Red Neuronal, Aprendizaje Automático, Diagnóstico Asistido por Ordenador, Interoperabilidad de Datos de Salud, Seguridad y Privacidad de Datos Médicos AI.

Abstract

This paper focuses on an implementation for the assignment of specialized medical personnel for the geriatric service, which is administratively carried out manually, according to a model of a Neural Network that incorporates the epidemiological behavior of the demand, the availability of the installed capacity, available schedules of the professionals, types of links, geographic locations where care is provided. The methodology used covers the process of collecting medical data, which are subjected to machine learning algorithms, which allow clinical validation and comparative evaluation with conventional standards. The methodological approach used shows that the data acquisition and processing strategies, the experimental design and the evaluation techniques guarantee a plausible precision, reliability and applicability of the AI models, for the branch and bound algorithm, in the medical context of the administration of the Geriatric service.

Recepción: 20 de Noviembre de 2023 / Evaluación: 05 de Febrero de 2024 / Aprobado: 12 de Abril de 2024

¹MSc. Universidad Distrital Francisco José de Caldas, Colombia. Email: gsilvar@udistrital.edu.co.

²PhD. Universidad Distrital Francisco José de Caldas, Colombia. Docente Universidad Distrital Francisco José de Caldas, Colombia. Email: aabucharp@udistrital.edu.co. ORCID: <https://orcid.org/0000-0001-8869-7129>

³PhD. En Ingeniería Informática, Pontificia de Salamanca campus Madrid, España. Docente Universidad Distrital Francisco José de Caldas, Colombia Email: rferro@udistrital.edu.co. ORCID: <https://orcid.org/0000-0002-8978-538X>.

Keywords: Artificial Intelligence in Medicine, Neural Network, Machine Learning, Computer Aided Diagnosis, Health Data Interoperability, AI Medical Data Security and Privacy.

Introducción

Este artículo presenta un trabajo de investigación que busca contribuir a darle solución a una problemática del sistema de salud enfocado a la gestión y tiene como objetivo desarrollar un modelo de asignación de médicos especialista para el servicio de geriatría en las entidades de salud, mediante el uso de la inteligencia artificial (IA) para gestionar los recursos y así la optimizar la asignación de personal de la salud, de acuerdo con la demanda, el uso de la capacidad instalada, entre otros aspectos, lo que redundará en la ampliación de la cobertura de la oferta del servicio de salud (Atefeh Amindoust et al., 2021; Robert Ojstersek et al., 2020).

Toda persona, en especial el adulto mayor, requiere atención rápida y eficiente a nivel médico, por ende, los servicios de salud ofertados por las instituciones precisan de una atención oportuna y específica, que busque una atención confiable, de calidad y un sistema sostenible económicamente, la prestación de los servicios de salud es un proceso ordenado y sincronizado el cual debe contar con una planificación en la atención, de recursos logísticos y presupuestales previo a ofertar los servicios de salud (Atefeh Amindoust et al., 2021).

Un servicio de salud efectivo y óptimo se basa en la planificación y la sincronización del sistema productivo para la prestación y cobertura de la oferta de los servicios de salud, siendo predominante la oportunidad de la atención del paciente por momento de curso de vida para que no se produzca o se desmejore sus condiciones de salud. La calidad en la atención de los servicios de salud se soporta en el conocimiento y experiencia del talento humano, reflejando en sus intervenciones en los procesos de atención de la salud de los pacientes un sin número de saberes o competencias laborales y comportamentales que van desde aprendizaje, trabajo en equipo, comunicación asertiva, entre otras, y que permiten cualificar el desempeño exitoso como elemento fundamental de la cultura organizacional.

La optimización de recursos y el aprovechamiento para la toma de decisiones es el tema central en el cual se soporta la planeación de los servicios como estrategia competitiva, ya que estos garantizan la prestación oportuna y con calidad de los servicios ofertados por las instituciones que prestan servicios de salud, un modelo de asignación de talento humano basado en técnicas de IA (Raúl Pino Díez et al., 2001; Russell et al., 2004), permitirá optimizar la asignación de profesionales de la salud, garantizando la prestación y cobertura de los servicios de salud, de forma oportuna, eficaz y con calidad, proyectando al máximo el uso de su capacidad instalada, el cubrimiento de la demanda de forma oportuna y la optimización de las tecnologías de salud (Ali Hassan Sodhro et al., 2019).

El talento humano dentro del sistema productivo y en especial en la medicina basada en la evidencia, se soporta en el conocimiento de los médicos quienes aportan sus habilidades, competencias y destrezas en aras de mantener las condiciones de salud de la población objeto de atención. Pero el problema se presenta, cuando la administración no cuenta con los instrumentos tecnológicos y administrativos para realizar la planeación estratégica y de operatividad en la prestación de los servicios. Por lo que un modelo de asignación de médicos especialistas que integre desde la proyección de la plataforma estratégica hasta la evaluación de la prestación optimizando el proceso del servicio permitiendo mantener la máxima cobertura de los servicios de salud, este modelo de asignación permite eliminar la incertidumbre y la falta de planeación y gestión (Alireza Nooraiepour et al., 2021).

Todo paciente, de acuerdo con su momento de curso de vida, en especial el adulto mayor, requiere atención rápida y eficiente, por ende los servicios de salud ofertados por las instituciones precisan de una atención oportuna y específica, buscando una atención confiable,

de calidad y un sistema sostenible económicamente, la prestación de los servicios de salud es un proceso ordenado y sincronizado el cual debe disponer de una planificación de la atención, de recursos logísticos y presupuestales previo a ofertar servicios de salud, siendo la asignación del talento humano la que refleja la operatividad de la estrategia propuesta en los planes de atención, además sino se hace una óptima asignación podría aumentar los problemas de salud de los pacientes y esto genera no solo un costo social alto, sino pérdidas económicas altas para el organización (Alireza Nooraiepour et al., 2021).

El principal problema que se enfrentan las organizaciones de salud no está en el desarrollo de los servicios, sino en dar soluciones a sus usuarios con relación a la ampliación de la cobertura de la oferta de servicios de salud, basado en la asignación de talento humano que permita de forma automática dar respuesta a la demanda fluctuante que presenta el sistema de salud y la optimización de los recursos como son: el talento humano, el uso de la capacidad y la atención oportuna de los servicios de salud (Alireza Nooraiepour et al., 2021).

La atención primaria o en las urgencias es la entrada al uso de un sistema de salud y es allí donde se muestra la capacidad resolutoria en busca de la solución oportuna, eficiente y óptima de las afecciones que presenta un usuario de servicios de salud. La efectividad se hace evidente cuando se mitiga, se controla o se trata la enfermedad o un evento adverso de salud, de forma oportuna y con calidad, si esto no se hace se puede convertir en un alto costo para la operación del sistema, ya que si no se cuenta con los instrumentos que apoyen la prestación de los servicios de nada sirven los esfuerzos que realice el personal de la salud, es por ello que una adecuada adopción de un modelo de asignación de personal de la salud que soporte la planeación y programación del médicos especialistas para el servicios de geriatría a fin de operar los planes de salud o las rutas integrales y con ello poder mejorar la calidad de vida de la población objeto de atención, esto se logra con el soporte de las técnicas de IA que le permita encontrar soluciones óptimas requeridas por el sistema y con dar solución al problema de ampliación de la cobertura de la oferta (Max Bramer, 2009).

En esta investigación, se desarrolla inicialmente una simulación de un modelo matemático para la asignación de personal de salud, basado en programación lineal en lenguaje de programación Python. Una vez desarrollado y se analizan los resultados de la optimización, se detecta si el problema persiste, ya que la solución del modelo de asignación no responde a la solución del cubrimiento total de la atención de la demanda en salud.

Por lo cual, la siguiente estrategia que se plantea es el uno de técnicas de IA que permita determinar el número óptimo de profesionales a asignar al servicio de geriatría y centros de atención, permitiendo solucionar el problema y así ampliar al máximo la cobertura de servicios, teniendo en cuenta como diferentes variables como el comportamiento fluctuante de la demanda, el uso máximo de la capacidad instalada, tipo de vinculación de los profesionales de la salud, disponibilidad de horarios personal médico, entre otros (Eduardo Francisco Caicedo & Jesús Alfonso López, 2009).

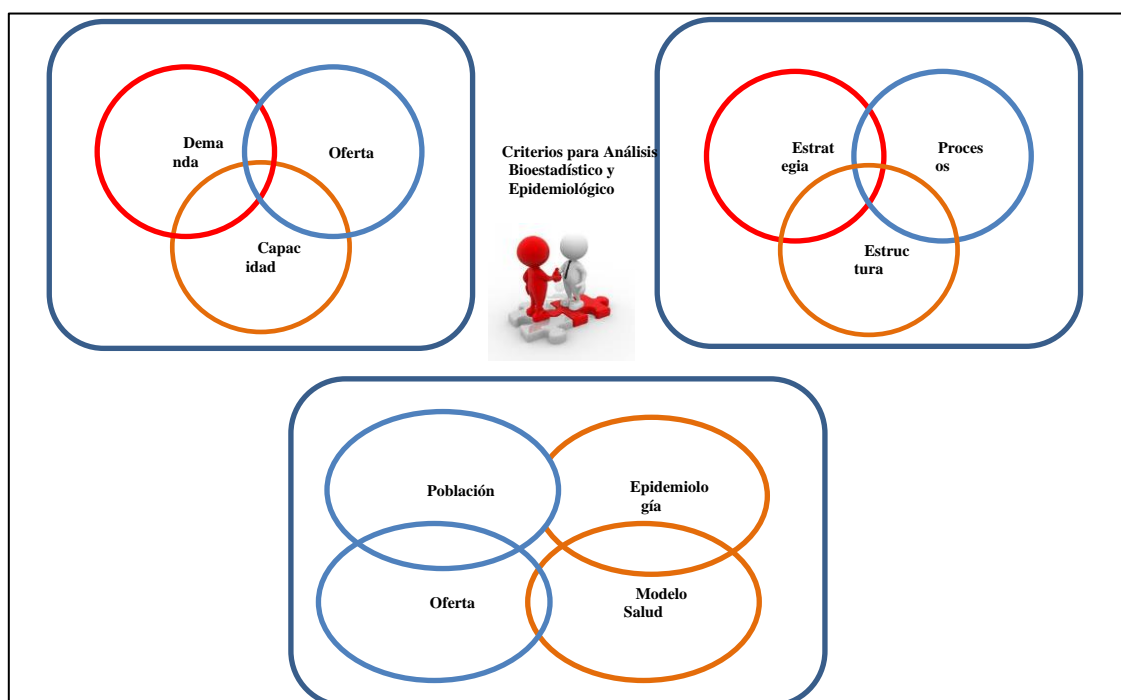
Metodología de la revisión

1. Método Subjetivo

El cálculo de necesidades de personal en salud, inicia de manera subjetiva determinando las variables de asignación, como lo indica la figura 1; luego pasa al Modelo de Optimización y finaliza con la aplicación de Técnicas de Inteligencia Artificial, En las entidades de salud, la asignación de personal médico especialistas para el servicio de geriatría se hace de acuerdo con el comportamiento epidemiológico de la demanda, la disposición de la capacidad instalada, horarios disponibles de los profesionales, tipos de vinculación, lugares geográficos donde presta la atención, en general el problema se centra en la ampliación de la cobertura de los servicios de salud basada en asignación y programación del personal médico la cual se hace de

forma manual para los cálculos de cantidades de personal, perfiles requeridos, disposición de horarios, ubicación, además contar con gran cantidad de información. Esta operación la realiza una sola persona, quien hace las proyecciones necesarias y después la dispone para la asignación de recursos presupuestales y posterior aprobación para la toma de decisiones de los responsables del proceso de atención, estas operaciones y las decisiones no están automatizadas y se basa en el conocimiento subjetivo de quien desarrolla esa función (Sardar Mehboob Hussain et al., 2022).

Figura 1. Variables en la Asignación Óptima de Médicos Especialistas en el Servicio de Geriatría



Nota: Fuente: Elaboración propia

La determinación de Necesidades de talento Humano a partir del análisis bioestadística y epidemiológico en el Sistema de Salud requiere de la definición de algunas variables a saber, tabla 1:

Tabla 1. Demanda Vs Oferta.

Demanda	Oferta
Población = Demanda = Epidemiología = Estrategia de Atención	Oferta = Modelo de salud = Procesos = Estructura = Capacidad
Demanda o población objeto de atención por momentos de curso de vida	Portafolio de servicios
Actividades Históricas y Esperadas en salud en un periodo determinado	Cantidad personal por vinculación en horas-día y perfil
Horas mes requeridas	Capacidad disponible
Estándar de servicio	Frecuencia de uso
Agendas	Cantidad personal requerido en horas-día y perfil

Nota: elaboración propia

Para realizar los cálculos del personal necesario para un servicio particular, se requiere definir:

- Frecuencia de Uso (FUE)

- Demanda Inducida (DIN)
- Efectiva o Histórica (DEH)
- Demanda No Atendida o Insatisfecha (DNA)
- Estándar de Servicio Salud (ESS)
- Actividades de Salud Esperadas
- Actividades de Salud Esperadas demanda efectiva e insatisfecha (ASEI)
- Actividades de Salud Esperadas Rutas Integrales de Atención en Salud (ASRI)
- Horas de Atención Requeridas Mes (HARM)
- Horas de Atención Requeridas Día (HARD)
- Cantidad Personal Requerido (CPR)
- Perfil Requerido Talento Humano

$$1. FUE = \frac{(DEH+DNA)}{Poblacion}$$

$$2. ASEI = \frac{FUE * (DEH + DNA)}{12}$$

$$3. ASRI = \frac{FUR * DIN}{12}$$

$$4. HARM = \left(\frac{(ASEI + ASRI) * ESS}{60} \right) = \frac{ASEI * ESS}{60} + \frac{ASRI * ESS}{60}$$

$$5. HARD = \frac{HARM}{24}$$

Método Optimización (Algoritmo de ramificación y acotamiento) Maximización o minimización de una solución a un problema prestablecido con unas condiciones llamadas restricciones (Cobo Ortega,2009.). El problema consiste en calcular para cada centro de atención del sistema del número de médicos especialistas (Personal Asistencial) requeridos en la prestación del servicio de geriatría a un mínimo costo y teniendo en cuenta:

- La cobertura de la proyección o pronóstico de la demanda.
- Capacidad disponible de los consultorios asociados a cada uno de los centros de atención en salud.
- Cada centro de atención oferta servicios
- El cálculo de personal debe tener directa relación entre la demanda proyectada o pronosticada, la capacidad disponible para cada centro de atención y la planta de personal de servidores públicos.
- Vinculación de cuatro (4), seis (6) y ocho (8) horas día para los médicos especialistas que prestaran el servicio en geriatría.
- Los horarios del personal médico especialista de planta son fijos, no hay rotación de horarios ni de centros de atención.

Conjunto de índices

Se emplean para controlar el barrido por los diferentes vectores y tablas de datos del modelo y son:

- Personal (i): {Pp8h, Pp6h, Pp4h, Co8h, Co6h, Co4h,}, está asociado al tipo de vinculación planta y contrato de prestación de servicios y tiempo de prestación de servicios (8horas/día, 6horas/día y 4 horas/día)
- Centros (j): { 1, 2, 3, 4, 5 }, número de centros de atención donde se presta el servicio.

- Periodos (k): {1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12}, hace referencia a los meses del año.

Arreglos: vectores de datos

htp [Personal]: horas laborales por tipo de personal.

ctp [Personal]: costo vinculación por tipo de personal.

pac [Personal, Centro]: personal a asignar por cada centro de atención.

dca [Centro, Periodos]: demanda pronosticada para cada centro de atención en cada periodo.

cca [Centro, Periodos]: capacidad disponible para cada centro de atención en cada periodo.

Parámetros: Estos se componen de las tablas de demanda, capacidad disponible de los centros de atención por periodo, tiempos de servicio por tipo de profesional, y costos de contratación tipo de profesional en cada periodo (Jarod David Pedraza Caro, 2023), los cuales se definen a continuación:

- Demanda pronosticada (dca) para cada centro de atención en cada periodo.
- Capacidad disponible (cca) para cada centro de atención en cada periodo.
- Horas laborales (htp) por tipo de vinculación y tiempo de prestación de servicios.
- Costo (ctp) por tipo de vinculación y tiempo de prestación de servicios.
- Costo (C_e) de contratación extra, el cual depende de los valores impuestos por el mercado de la salud
- Cotas (pac) personal de planta a asignar en primeras en cada periodo.
- Eficiencia (efic) del tiempo laboral, estimado por la institución en un 90% para desarrollar actividades de atención de pacientes (Actividades asistenciales) y el restante 10% en actividades administrativas y de gestión relacionadas con el servicio (Desarrollar cursos de prevención y promoción, entre otros).

Personal médico Especialista.

La institución vincula (Contrata) a médicos especialistas para laborar mediante dos (2) formas:

- Planta (NU8h, NU6h y NU4h): Ingresa a la planta de personal a laborar con un contrato a término indefinido como médico especialista con dedicación de 8, 6 o 4 horas día (Fatih Yiğit, 2023; Wang, 2022).
- Contratistas de prestación de servicios profesionales (Co8h, Co6h y Co4h): Ingresa a laborar con un contrato a término fijo y con remuneración por honorarios de prestación de servicios profesionales, con el fin de atender el total de la demanda en los diferente establecimiento de sanidad, se procede a asignar en orden de vinculación a los profesionales de planta y si la demanda no se cubre en su totalidad, se realiza la contratación de médicos por prestación de servicios profesiones de acuerdo con el tiempo requerido, el cual va desde cero (0) hasta un tiempo de 8, 6 o 4 horas por día según políticas y programas de la salud de la Institución (Jacques Ferber, 1999).
- Adicionalmente a las labores asistenciales (atención a pacientes), todo el personal médico tiene tiempos para labores administrativas relacionadas con esta función, y está estimado en un 10% del total de tiempo contratado de las horas mes (Nelly Flores, 2023).

Restricciones

- Demanda: Cantidad requerida de profesionales para atender la demanda del servicio de geriatría en cada periodo.

- Capacidad: Cantidad de profesionales según tipo de vinculación a ser asignado de acuerdo con la capacidad disponible de cada centro de atención en cada periodo.
- Personal1 (X_{ijk}); garantiza que la asignación se realice dando prioridad al personal actual planta de 8, 6 y 4 horas día.
- Personal2 (Y_{ijk}); realiza la asignación del personal de contrato por prestación de servicios, una vez asigne en primer lugar al personal planta de 8, 6 y 4 horas día.

Variables decisión:

X_{ijk} = Cantidad de profesionales requeridos y asignados con vinculación tipo i en el centro de atención j en el periodo k contratados de manera regular.

Y_{ijk} = Cantidad de profesionales requeridos extra y asignados con vinculación tipo i en el centro de atención j en el periodo k .

Modelo Matemático.

Función Objetivo

$$\text{Minimizar} = \sum_i^{\text{Personal}} \sum_j^{\text{Centro}} \sum_k^{\text{Periodo}} ctp_i * X_{ijk} + \sum_i^{\text{Personal}} \sum_j^{\text{Centro}} \sum_k^{\text{Periodo}} ctpe * Y_{ijk} \quad (1)$$

ó

$$\text{Minimizar} = \sum_i^{\text{Personal}} \sum_j^{\text{Centro}} \sum_k^{\text{Periodo}} (ctp_i * X_{ijk} + ctpe * Y_{ijk}) \quad (1)$$

Sujeto a las restricciones

Restricción debido a la satisfacción de la demanda en los centros de atención

Demanda (j, k):

$$\sum_i^{\text{Personal}} efi * htp_i * (X_{ijk} + Y_{ijk}) \geq dca_{jk} \forall i: 1 \dots 9, j: 1 \dots 10, k: 1 \dots 12 \quad (2)$$

Restricción debido a la capacidad en los centros de atención

Capacidad (j, k):

$$\sum_i^{\text{Personal}} efi * htp_i * X_{ijk} \leq cca_{jk} \forall i: 1 \dots 9, j: 1 \dots 10, k: 1 \dots 12 \quad (3)$$

Restricciones debido a la asignación de personal dando prioridad a los servidores públicos vinculados a la planta de personal planta:

Personal1 (i, j, k):

$$X_{ijk} \geq pac_{ij} \forall i: 1 \dots 9, j: 1 \dots 10, k: 1 \dots 12 \quad (4)$$

Restricciones que garantiza el calcular y asignar el personal por prestación de servicios faltante una vez se haya asignado el personal vinculado a la planta de personal:

Personal2 (i, j, k):

$$X_{ijk} \leq pac_{ij} \forall i: 1 \dots 9, j: 1 \dots 10, k: 1 \dots 12 \quad (5)$$

Restricción de no negatividad y tipo de variable

$$X_{ijk} \geq 0 \forall i, j, k \quad (6)$$

$$Y_{ijk} \geq 0 \forall i, j, k \quad (7)$$

$$X_{ijk}, Y_{ijk} \in Z \forall i, j, k \quad (8)$$

Modelo con técnica de Inteligencia artificial

La tecnología actual basada en la IA, ha generado unas nuevas estrategias competitivas para dar respuesta a las necesidades de un mercado meta, el cual busca posicionarse en todas las latitudes, con el fin de monopolizar el mercado y basado en desarrollos tecnológicos que permiten comprometer más al cliente mediante la interacción con aplicaciones informáticas que asemejan la inteligencia humana, el uso de la tecnología provoca que las organizaciones se enfrenten competitivamente no solo para el desarrollo de productos, sino la logística y

gestión de operaciones de tal forma que su respuesta oportuna al mercado se fundamenta en el diseño de un modelo de gestión de operaciones que integre el sistema de información como un todo de forma holística y sus recursos de entrada como el talento humano, materiales y suministro, maquinaria y equipo, método entre otros, que se interrelacionen y procesen dando como resultado final un bien o un servicio (producto), en aras de mantenerse obligadamente en un mercado altamente competitivo (Chen et al., 2023; John Fulcher, 2006).

La IA, hoy en día, hace parte de la tecnología requerida en la planificación y satisfacción constante de las necesidades de salud de una población objeto de atención, que facilita la toma de decisiones, cuando el sistema de gestión de salud genera grandes volúmenes de información de los cuales deben ser extraídos, clasificados y analizados como soporte del desempeño de la estrategia competitiva de las organizaciones que busca la eficiencia y eficacia del proceso de modelación de la asignación de médicos especialistas en el servicios de salud de geriatría (Jackeline Granados Ferreira, 2022).

Desarrollo

En el diseño de la Red neuronal, figura 2, para la asignación de personal, se emplea un modelado de la relación entre la demanda de servicios de salud de un centro de atención y la oferta de servicios, principalmente la necesidad de personal para garantizar la prestación y la cobertura a lo largo de distintos intervalos periodos. El proceso de entrenamiento del modelo se lleva a cabo de manera individualizada para cada centro de atención, utilizando datos de entrenamiento que abarcan un período completo de un año, desde enero hasta diciembre. Estos datos incluyen diversas asignaciones de personal a lo largo de dicho intervalo temporal (Fernando Filgueiras, 2021; Sidorov Gerhard Ritter Jean Serra Ulises Cortés, n.d.).

La premisa fundamental consiste en entrenar al modelo para generar asignaciones de personal en correlación con la cantidad de las horas demandadas y la elección del centro médico (Deng et al., 2023).

El enteramiento se realizó con la demanda de los centros médicos, tabla 2:

Tabla 2. Demanda, capacidad de centros médicos, asignación de personal.

<i>Centro de Atención</i>	Ene	Feb	Mar	Abr	May	Jun	Jul	<u>Ago</u>	<u>Sep</u>	Oct	Nov	Dic
CA01	856	161 5	147 3	253 9	159 0	264 9	241 0	275 9	287 0	275 9	156 1	142 1
CA02	100 6	420	878	110 9	112 3	102 2	100 9	843	102 3	101 1	792	864
CA03	100 9	108 3	808	841	959	909	340	165 5	102 1	802	777	126 8
CA04	744	857	122 6	117 2	137 9	132 4	132 4	137 9	143 5	109 8	109 7	828
CA05	751	773	722	761	827	794	794	624	672	580	677	621

Nota: elaboración propia

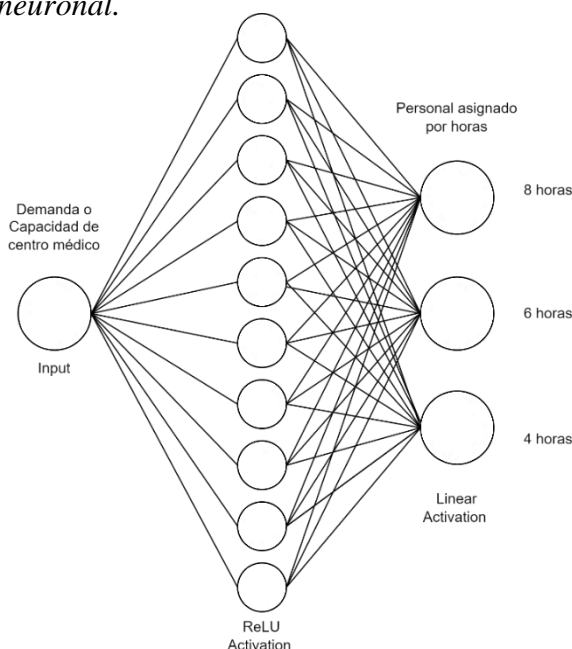
Así como también se entrenaron los modelos con la capacidad de los centros médicos

Centro de Atención	Ene	Feb	Mar	Abr	Ma y	Jun	Jul	Ago	Sep	Oct	Nov	Dic
CA01	299 9	287 9	311 9	275 9	299 9	287 9	287 9	299 9	311 9	299 9	287 9	287 9
CA02	239 9	230 3	249 5	220 7	239 9	230 3	230 3	239 9	249 5	239 9	230 3	230 3
CA03	179 9	172 7	187 1	165 5	179 9	172 7	172 7	179 9	187 1	179 9	172 7	172 7
CA04	149 9	143 9	155 9	137 9	149 9	143 9	143 9	149 9	155 9	149 9	143 9	143 9
CA05	899	863	935	827	899	863	863	899	935	899	863	863

Relacionándola con los datos de asignación de personal

Centro de Atención	Enero			Febrero			Marzo			Abril			Mayo			Junio			Julio			Agosto			Septiembre			Octubre			Noviembre			Diciembre		
Horas/Día	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4	8	6	4
CA01	2	0	1	2	0	1	2	0	1	2	0	1	2	0	1	1	0	0	1	0	0	1	0	0	2	0	1	2	0	1	2	0	1	2	0	1
CA02	0	2	3	0	2	3	0	2	3	0	2	3	0	2	3	0	1	2	0	1	2	0	1	2	0	2	3	0	2	3	0	2	3	0	2	3
CA03	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
CA04	1	0	3	1	0	3	1	0	3	1	0	3	1	0	3	0	0	2	0	0	2	0	0	2	1	0	3	1	0	3	1	0	3	1	0	3
CA05	0	2	2	0	2	2	0	2	2	0	2	2	0	2	2	0	1	1	0	1	1	0	1	1	0	2	2	0	2	2	0	2	2	0	2	2

Figura 2. Red neuronal.



Nota: fuente: elaboración propia.

Se procedió a la partición del conjunto de datos, asignando el 70% para el entrenamiento y el 30% restante para la validación. Inicialmente, los modelos fueron entrenados con el objetivo de anticipar las asignaciones, basándose en la cantidad de horas demandadas.

Posteriormente, se utilizó el número de horas contenido en la tabla de capacidad, resultando en la generación de una tabla de Error Cuadrático Medio (MSE) correspondiente a cada uno de los centros médicos (Jagatheesaperumal et al., 2021; Lenin et al., 2023).

```

losts per model dca
{'CA01': 109665.078125, 'CA02': 36698.6796875, 'CA03': 41536.7890625, 'CA04': 54382.8359375, 'CA05': 32278.166015625}

losts per model cca
{'CA01': 1042967.0625, 'CA02': 876248.875, 'CA03': 455032.03125, 'CA04': 99632.0625, 'CA05': 19.337663650512695}

```

Modelo	DCA	CCA
CA01	109665,08	1042967,06
CA02	36698,68	876248,88
CA03	41536,79	455032,03
CA04	54382,84	99632,06
CA05	32278,17	19,34
Promedio	54912,31	494779,87

Los elevados índices de error revelan que la propuesta de modelo para la asignación de personal a través de redes neuronales exhibe un desempeño inferior en comparación con el enfoque del problema mediante algoritmos de optimización, los cuales incorporan variables adicionales relacionadas con precios, tiempos y lógica empresarial (Jagatheesaperumal et al., 2021; Zhang, 2023). La codificación en Python se puede observar en el anexo 1.

Conclusiones

El uso de la inteligencia artificial en medicina está revolucionando la forma en que se diagnostican enfermedades y se personalizan los tratamientos, lo que conlleva un impacto transformador en la eficiencia y la precisión de la atención médica. Las tecnologías de IA, como el aprendizaje automático y las redes neuronales, han demostrado una capacidad significativa para mejorar la precisión en el diagnóstico de enfermedades, incluso en etapas tempranas, lo que puede conducir a intervenciones más efectivas y oportunistas.

La capacidad de la IA para analizar grandes conjuntos de datos clínicos permite la medicina personalizada, adaptando tratamientos y enfoques a las necesidades específicas de cada paciente, lo que puede mejorar los resultados y reducir los efectos secundarios. A medida que se implementan sistemas de IA en la práctica médica, surgen desafíos éticos y regulatorios, incluyendo la privacidad de los datos, la transparencia en los algoritmos y la responsabilidad en la toma de decisiones clínicas.

Es crucial la colaboración interdisciplinaria entre profesionales de la salud, científicos de datos, expertos en ética y reguladores para desarrollar estándares éticos y protocolos que garanticen la seguridad, la confiabilidad y la equidad en la aplicación de la IA en medicina. La investigación continua y la validación clínica rigurosa son esenciales para perfeccionar los modelos de IA, mejorar su precisión y asegurar su integración efectiva en entornos médicos reales. A pesar de los desafíos, el potencial futuro de la inteligencia artificial en medicina es prometedor, con la posibilidad de revolucionar aún más la atención médica, mejorar los resultados para los pacientes y optimizar los recursos sanitarios.

En otras perspectivas de investigación en términos de la gestión y administración de la atención geriátrica en presencia de IA se cuentan la Administración de Medicamentos, desarrollando aplicaciones de recuerdo y alerta familiar o al cuidador; la Asistencia en el

Hogar, que incluye desarrollar funcionalidades para facilitar la vida de los ancianos de tipo domótico: comandos de voz, sugerencia de actividades o recordatorios; la Detección de Caídas, con desarrollos de Sensores para detección y alerta a servicios de emergencia o familiares; el Compromiso Social y Emocional, desarrollando aplicaciones de compañía virtual y de contacto con Familiares y Amigos desarrollando aplicaciones y dispositivos para asistir a los mayores a hacer videollamadas disminuyendo la sensación de soledad; o el mismo Entrenamiento Digital a las personas de la tercera edad en el uso de la tecnología. Todas opciones de corte administrativo a la propuesta desarrollada en la presente investigación.

Anexo 1. Programación Python

Código realizado

```
# cargue de librerías
import numpy as np
import pandas as pd
import tensorflow as tf
from sklearn.model_selection import train_test_split

# Cargue de datos
# Se recupera la información de excel y se asigna a un dataframe que contiene
# las diferentes páginas de excel.
input_file = r'.\datos_modelo_geriatria.xlsx'
sheet_names_to_read = ['capacidad-CA', 'demanda-CA', 'personal-data', 'clasificacion-
personal']
data_frames = {}

for sheet_name in sheet_names_to_read:
    # Read data from the Excel file into a Pandas DataFrame
    df = pd.read_excel(input_file, sheet_name=sheet_name)
    data_frames[sheet_name] = df

# Recuperación de datos en dataframes
# Se asignan la información a dataframes específicos y se asignan multiindex
# para poder acceder más fácilmente a la información.
dca = data_frames['demanda-CA']
dca = dca.set_index(['Centro de Atención'])
multi_index = pd.MultiIndex.from_product([dca.columns, dca.index],
                                         names=['mes', 'Centro de Atención'])
dca = dca.T

cca = data_frames['capacidad-CA']
cca = cca.set_index(['Centro de Atención'])
cca = cca.T

pca = data_frames['personal-data']
pca_values = pca.values
rows = ['CA01', 'CA02', 'CA03', 'CA04', 'CA05']
months = ['Enero', 'Febrero', 'Marzo', 'Abril', 'Mayo', 'Julio', 'Junio', 'Agosto',
'Septiembre', 'Octubre', 'Noviembre', 'Diciembre']
```

```

hours = ['8','6','4']
cols = pd.MultiIndex.from_product([months, hours])
pca_df = pd.DataFrame(pca_values, index=rows, columns=cols)

# Entrenamiento de modelo usando demanda
loss_per_model_dca = {}
for row in rows:
    X = dca[row]
    y = pca_df.loc[row].to_numpy().reshape(12, -1)
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=42)

    # Define the model
    model = tf.keras.Sequential([
        tf.keras.layers.Dense(10, activation='relu', input_shape=(1,)),
        tf.keras.layers.Dense(3, activation='linear', dtype='float32')
    ])
    # Compile the model
    model.compile(optimizer='adam', loss='mean_squared_error')

    # Train the model
    model.fit(X_train, y_train, epochs=50, validation_data=(X_test, y_test), verbose=2)

    # Evaluate the model on the test set
    loss = model.evaluate(X_test, y_test)
    print(f'Test Loss: {loss}')
    loss_per_model_dca.update({row:loss})

    # Make predictions on new data
    predictions = model.predict(X_test)

    # Convert predictions to integers and replace negatives with 0
    predictions_rounded = np.where(predictions < 0, 0, predictions.astype(int))

    # Evaluate the rounded predictions
    rounded_loss = model.evaluate(X_test, predictions_rounded)
    print(f'Test Loss with Rounded Predictions: {rounded_loss}')

    print(f'Rounded Predictions:\n{predictions_rounded}')

    # Save the model
    model.save(f"model_for_{row}.h5")
    print(f"Model for {row} trained and saved.")

print('Losses per model dca')
print(loss_per_model_dca)

```

```

# Entrenamiento de modelo usando capacidad
loss_per_model_cca = {}
for row in rows:
    X = cca[row]
    y = pca_df.loc[row].to_numpy().reshape(12, -1)
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=42)

    # Define the model
    model = tf.keras.Sequential([
        tf.keras.layers.Dense(10, activation='relu', input_shape=(1,)),
        tf.keras.layers.Dense(3, activation='linear', dtype='float32')
    ])
    # Compile the model
    model.compile(optimizer='adam', loss='mean_squared_error')

    # Train the model
    model.fit(X_train, y_train, epochs=50, validation_data=(X_test, y_test), verbose=2)

    # Evaluate the model on the test set
    loss = model.evaluate(X_test, y_test)
    print(f'Test Loss: {loss}')
    loss_per_model_cca.update({row:loss})

    # Make predictions on new data
    predictions = model.predict(X_test)

    # Convert predictions to integers and replace negatives with 0
    predictions_rounded = np.where(predictions < 0, 0, predictions.astype(int))

    # Evaluate the rounded predictions
    rounded_loss = model.evaluate(X_test, predictions_rounded)
    print(f'Test Loss with Rounded Predictions: {rounded_loss}')

    print(f'Rounded Predictions:\n{predictions_rounded}')

    # Save the model
    model.save(f"model_cca_for_{row}.h5")
    print(f'Model for {row} trained and saved.")

print('losses per model cca')
print(loss_per_model_cca)

```

Referencias Bibliográficas

- Ali Hassan Sodhro, Mohammad S. Obaidat, Sandeep Pirbhulal, & Gul Hassan Sodhro. (2019). A Novel Energy Optimization Approach for Artificial Intelligence-enabled Massive Internet of Things. *IEEE Xplore*.
- Alireza Nooraiepour, Waheed U. Bajwa, & Narayan B. Mandayam. (2021). *A hybrid model-based and learning-based approach for classification using limited number of training samples*.
- Atefeh Amindoust, Milad Asadpour, & Samineh Shirmohammadi. (2021). A Hybrid Genetic Algorithm for Nurse Scheduling Problem considering the Fatigue Factor. *NIH National Library of Medicine*.
- Chen, C., Fu, H., Zheng, Y., Tao, F., & Liu, Y. (2023). The advance of digital twin for predictive maintenance: The role and function of machine learning. In *Journal of Manufacturing Systems* (Vol. 71, pp. 581–594). Elsevier B.V. <https://doi.org/10.1016/j.jmsy.2023.10.010>
- Cobo Ortega, Á. (n.d.). *UNIVERSIDAD NACIONAL DE EDUCACIÓN A DISTANCIA Centro Asociado de Cantabria Lección Inaugural del Curso 2000-2001 ÁNGEL COBO ORTEGA Profesor Tutor*.
- Deng, J., Sierla, S., Sun, J., & Vyatkin, V. (2023). Mass customization with reinforcement learning: Automatic reconfiguration of a production line. *Applied Soft Computing*, 145. <https://doi.org/10.1016/j.asoc.2023.110547>
- Eduardo Francisco Caicedo, & Jesús Alfonso López. (2009). *UNA APROXIMACIÓN PRÁCTICA A LAS REDES NEURONALES ARTIFICIALES*.
- Fatih Yiğit. (2023). *A novel type-2 hexagonal fuzzy logic approach for predictive safety stock management for a distribution business*.
- Fernando Filgueiras. (2021). *Inteligencia Artificial en la administración pública: ambigüedad y elección de sistemas de IA y desafíos de gobernanza digital*.
- Jackeline Granados Ferreira. (2022). *Análisis de la inteligencia artificial en las relaciones laborales*.
- Jacques Ferber. (1999). *Multi-Agent System: An Introduction to Distributed Artificial Intelligence*.
- Jagatheesaperumal, S. K., Rahouti, M., Ahmad, K., Al-Fuqaha, A., & Guizani, M. (2021). *The Duo of Artificial Intelligence and Big Data for Industry 4.0: Review of Applications, Techniques, Challenges, and Future Research Directions*. <http://arxiv.org/abs/2104.02425>
- John Fulcher. (2006). *Advances in applied artificial intelligence /*.
- Lenin, F., Satama, V., Andrés, G., & Terán, F. (2023). Enero-Junio 2023. In *Revista ComHumanitas* (Vol. 14, Issue 1). <https://orcid.org/0000->
- Max Bramer. (2009). *Artificial Intelligence. An International Perspective*.
- Nelly Flores. (2023). *El Impacto de la Inteligencia Artificial en la Actualidad*.
- Raúl Pino Díez, Alberto Gómez Gómez, & Nicolás de Abajo Martínez. (2001). *Introducción a la inteligencia artificial*.
- Robert Ojstersek, Miran Brezocnik, & Borut Buchmeister. (2020). Multi-objective optimization of production scheduling with evolutionary computation: A review. *ResearchGate*.
- Russell, S. J. (Stuart J., Norvig, Peter., Corchado Rodríguez, J. Manuel., & Joyanes Aguilar, Luis. (2004). *Inteligencia artificial : un enfoque moderno*. Pearson Prentice Hall.
- Sardar Mehboob Hussain, Antonio Brunetti, Giuseppe Lucarelli, & Ricardo Memeo. (2022). Deep Learning Based Image Processing for Robot Assisted Surgery: A Systematic Literature Survey. *IEEE Xplore*.

- Sidorov Gerhard Ritter Jean Serra Ulises Cortés, G. (n.d.). *Research in Computing Science Series Editorial Board Comité Editorial de la Serie Editors-in-Chief: Editores en Jefe*. <http://www.cic.ipn.mx>
- Wang, T. (2022). A Novel Approach of Integrating Natural Language Processing Techniques with Fuzzy TOPSIS for Product Evaluation. *Symmetry*, 14(1). <https://doi.org/10.3390/sym14010120>
- Zhang, L. (2023). *A Novel Framework for Future Natural Language Processing From a Database Perspective*. <https://doi.org/10.13140/RG.2.2.33740.80001>