



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE HIDALGO

ESCUELA SUPERIOR DE TEPEJI DEL RÍO

MAESTRÍA EN GESTIÓN Y DESARROLLO

DE NUEVAS TECNOLOGÍAS

PROYECTO TERMINAL

**SISTEMA PREDICTOR DE LA DEMANDA DE MEDICAMENTOS APLICANDO
TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**

Para obtener el grado de

Maestro en Gestión y Desarrollo de Nuevas Tecnologías

PRESENTA

Missael Dominguez Martínez

Director(a)

Dra. Silvia Soledad Moreno Gutiérrez

Tepeji del Río de Ocampo, Hidalgo, diciembre 2025



Universidad Autónoma del Estado de Hidalgo
Escuela Superior de Tepeji del Río
Campus Tepeji del Río

OFICIO NÚM. ESTE-673-2025

ING. MISSAEL DOMÍNGUEZ MARTÍNEZ
ALUMNO DE LA MAESTRÍA EN GESTIÓN Y DESARROLLO DE NUEVAS TECNOLOGÍAS
ESCUELA SUPERIOR DE TEPEJI DEL RÍO
P R E S E N T E

AT'N: M. EN I. HÉCTOR DANIEL MOLINA RUIZ
COORDINADOR DE POSGRADO
ESCUELA SUPERIOR DE TEPEJI DEL RÍO

Por este medio, envío a usted mis mejores deseos, al tiempo que espero que el presente le encuentre a usted, a los suyos y a su equipo de trabajo, en pleno estado de salud. Aunado a lo anterior y con fundamento en el Capítulo V, Artículo 51, Fracciones III y IX del Estatuto General de nuestra Universidad, le informo que se ha autorizado la impresión de su propuesta de tesis, intitulada **“Sistema predictor de la demanda de medicamentos aplicando técnicas de aprendizaje automático”**.

Sin más por el momento, me reitero a sus distinguidas órdenes y quedo atento a sus comentarios e indicaciones.

ATENTAMENTE
“AMOR, ORDEN Y PROGRESO”
TEPEJI DEL RÍO DE OCAMPO, HGO., 02 DE DICIEMBRE DEL AÑO 2025

MTRO. GUADALUPE ISRAEL FLORES ARIZA

DIRECTOR

c.c.p. Archivo
GIFA/hdmr/lpro*25

Avenida del Maestro No. 41, Colonia Noxtongo
Segunda Sección, Tepeji del Río de Ocampo, Hidalgo,
México; C.P. 42855
Teléfono: 7717172000 Ext. 50401
estr@uaeh.edu.mx

“Amor, Orden y Progreso”



2025



uaeh.edu.mx

ÍNDICE GENERAL

1	CAPÍTULO I.....	1
1.1	Introducción	1
1.2	Apartados de la Tesis	4
1.3	Planteamiento del problema	5
1.4	Justificación	7
1.5	Objetivo general.....	9
1.6	Objetivos específicos	9
1.7	Delimitación y Alcance	10
2	CAPÍTULO II.....	11
2.1	Estado del Arte	11
2.2	Marco Teórico	18
3	CAPÍTULO III.....	33
3.1	Metodología	33
3.2	Comprensión del negocio	33
3.3	Objetivos de la organización	35
3.4	Evaluación de la situación actual	36
3.5	Objetivos del proyecto.....	37
3.6	Planificar el proyecto.....	37
3.7	Comprensión de los datos	38
3.8	Recolección de datos iniciales	38
3.9	Descripción de los datos	40
3.10	Exploración de los datos	41
3.11	Calidad de los datos.....	53
3.12	Selección de los datos	54
3.13	Limpieza de los datos	56
3.14	Integración de los datos	57
3.15	Transformación de los datos.....	58
3.16	Reducción de dimensiones	59
3.17	Modelado	61
3.18	Técnicas de modelado	62

ÍNDICE GENERAL

3.19	Modelo	65
3.20	Ajuste de los parámetros	70
3.21	Validación	73
3.22	Rendimiento del modelo	78
3.23	Determinación de los próximos pasos	95
3.24	Implementar el modelo.....	98
3.25	Monitoreo y rendimiento.....	99
4	CAPÍTULO IV	101
4.1	Resultados	101
4.2	Conclusiones	105
4.3	Referencias.....	109

ÍNDICE DE TABLAS

Tabla 3.1 Descripción de las variables. Fuente: Elaboración propia.	40
Tabla 3.2 Estadística de consumo en piezas de medicamentos por estado. Fuente: Elaboración propia.	47
Tabla 3.3 Número de épocas por estado. Fuente: Elaboración propia.	71
Tabla 3.4 Resultados de métricas de evaluación. Fuente: Elaboración propia.	73
Tabla 3.5 Intervalos de desempeño para resultados. Fuente: Elaboración propia.	74
Tabla 3.6 Modelos con alto rendimiento. Fuente: Elaboración propia.	75
Tabla 3.7 Modelos con medio rendimiento. Fuente: Elaboración propia.	76
Tabla 3.8 Estados piloto para la etapa de prueba del modelo. Fuente: Elaboración propia.	95

ÍNDICE DE DIAGRAMAS

Diagrama 3.1 Red de distribución de medicamentos tipo A. Fuente: Elaboración propia.	34
Diagrama 3.2 Red de distribución de medicamentos tipo B. Fuente: Elaboración propia.	35
Diagrama 3.3 Diagrama de flujo para el cálculo de pronóstico actual. Fuente: Elaboración propia.	36
Diagrama 3.4 Mapa de calor de consumo por piezas de medicamentos por estado. Fuente: Elaboración propia.	49
Diagrama 3.5 Grupo de insumos. Fuente: Elaboración propia.	54
Diagrama 3.6 Distribución porcentual de consumo. Fuente: Elaboración propia.	55
Diagrama 3.7 Diagrama de unión para consulta de información, fuente: elaboración propia.	58
Diagrama 3.8 Arquitectura del modelo de predicción. Fuente: Elaboración propia.	68
Diagrama 3.9 Diagrama de flujo del nuevo modelo de abasto. Fuente: Elaboración propia.	97

ÍNDICE DE GRÁFICAS

Gráfica 3.1 Datos generados de consumos de medicamentos por año. Fuente: Elaboración propia.	41
Gráfica 3.2 Número de medicamentos distintos, consumidos por año. Fuente: Elaboración propia.	42
Gráfica 3.3 Los 10 medicamentos de mayor consumo global. Fuente: Elaboración propia.	43
Gráfica 3.4 Top 10 de medicamentos con menor consumo global. Fuente: Elaboración propia.	45
Gráfica 3.5 Top 10 de consumos de medicamentos en el estado de Sonora. Fuente: Elaboración propia.	50
Gráfica 3.6 Resultados promedio de coeficiente de determinación en técnicas de modelos de predicción. Fuente: Elaboración propia.	64
Gráfica 3.7 Rendimiento de los modelos, según el Coeficiente de Determinación. Fuente: Elaboración propia.	77
Gráfica 3.8 Rendimiento del modelo para el estado de Aguascalientes. Fuente: Elaboración propia.	79
Gráfica 3.9 Rendimiento del modelo para el estado de Baja California Sur. Fuente: Elaboración propia.	79
Gráfica 3.10 Rendimiento del modelo para el estado de Baja California Norte. Fuente: Elaboración propia.	80
Gráfica 3.11 Rendimiento del modelo para el estado de Campeche. Fuente: Elaboración propia.	80
Gráfica 3.12 Rendimiento del modelo para el estado de Chiapas. Fuente: Elaboración propia.	81
Gráfica 3.13 Rendimiento del modelo para el estado de Chihuahua. Fuente: Elaboración propia.	81

ÍNDICE DE GRAFICAS

Gráfica 3.14 Rendimiento del modelo para el estado de Ciudad de México. Fuente: Elaboración propia	82
Gráfica 3.15 Rendimiento del modelo para el estado de Coahuila. Fuente: Elaboración propia	82
Gráfica 3.16 Rendimiento del modelo para el estado de Colima. Fuente: Elaboración propia.....	83
Gráfica 3.17 Rendimiento del modelo para el estado de Durango. Fuente: Elaboración propia.....	83
Gráfica 3.18 Rendimiento del modelo para el Estado de México. Fuente: Elaboración propia	84
Gráfica 3.19 Rendimiento del modelo para el estado de Guanajuato. Fuente: Elaboración propia .	84
Gráfica 3.20 Rendimiento del modelo para el estado de Guerrero. Fuente: Elaboración propia	85
Gráfica 3.21 Rendimiento del modelo para el estado de Hidalgo. Fuente: Elaboración propia	85
Gráfica 3.22 Rendimiento del modelo para el estado de Jalisco. Fuente: Elaboración propia	86
Gráfica 3.23 Rendimiento del modelo para el estado de Michoacán. Fuente: Elaboración propia ...	86
Gráfica 3.24 Rendimiento del modelo para el estado de Morelos. Fuente: Elaboración propia	87
Gráfica 3.25 Rendimiento del modelo para el estado de Nayarit. Fuente: Elaboración propia	87
Gráfica 3.26 Rendimiento del modelo para el estado de Nuevo León. Fuente: Elaboración propia	88
Gráfica 3.27 Rendimiento del modelo para el estado de Oaxaca. Fuente: Elaboración propia	88
Gráfica 3.28 Rendimiento del modelo para el estado de Puebla. Fuente: Elaboración propia.....	89
Gráfica 3.29 Rendimiento del modelo para el estado de Querétaro. Fuente: Elaboración propia	89
Gráfica 3.30 Rendimiento del modelo para el estado de Quintana Roo. Fuente: Elaboración propia	90
Gráfica 3.31 Rendimiento del modelo para el estado de San Luis Potosí. Fuente: Elaboración propia	90
Gráfica 3.32 Rendimiento del modelo para el estado de Sinaloa. Fuente: Elaboración propia.....	91
Gráfica 3.33 Rendimiento del modelo para el estado de Sonora. Fuente: Elaboración propia	91
Gráfica 3.34 Rendimiento del modelo para el estado de Tabasco. Fuente: Elaboración propia.....	92
Gráfica 3.35 Rendimiento del modelo para el estado de Tamaulipas. Fuente: Elaboración propia .	92
Gráfica 3.36 Rendimiento del modelo para el estado de Tlaxcala. Fuente: Elaboración propia	93
Gráfica 3.37 Rendimiento del modelo para el estado de Veracruz. Fuente: Elaboración propia	93
Gráfica 3.38 Rendimiento del modelo para el estado de Yucatán. Fuente: Elaboración propia	94
Gráfica 3.39 Rendimiento del modelo para el estado de Zacatecas. Fuente: Elaboración propia....	94
Gráfica 4.1 Gráfico de dispersión de rendimiento para un estado. Fuente: Elaboración propia	103

ÍNDICE DE MATRICES

Matriz 3.1 Matriz de correlación para el estado de Sonora. Fuente: Elaboración propia.	51
---	----

AGRADECIMIENTOS

En primer lugar, deseo expresar mi más profundo agradecimiento a mi familia, por su apoyo incondicional, comprensión y motivación constante a lo largo de toda mi formación académica, gracias por impulsarme siempre a seguir adelante, incluso en los momentos de mayor dificultad, y por creer en mí y en mis capacidades, su acompañamiento ha sido fundamental para mi crecimiento personal y profesional.

A mi hija y a mi esposa, quienes han sido mi mayor fuente de inspiración y el motor que me impulsa a superarme cada día, su amor, su presencia y cada una de sus sonrisas me han brindado la fortaleza necesaria para no rendirme y continuar persiguiendo mis metas con mayor determinación, esfuerzo y esperanza.

A mis profesores, por compartir sus conocimientos, experiencia y orientación a lo largo de mi carrera, sus enseñanzas y consejos han sido clave para el desarrollo de este trabajo y para mi formación académica, asimismo, agradezco a mis compañeros, por el apoyo, el trabajo en equipo y las experiencias compartidas, que enriquecieron este proceso de aprendizaje y experiencia.

Finalmente, agradezco a todas las personas que, de manera directa o indirecta, contribuyeron a la realización de esta tesis y a la culminación de esta etapa tan importante de mi vida académica.

1 CAPÍTULO I

1.1 Introducción

¿Por qué es importante conocer el futuro? A lo largo del tiempo, la predicción se ha convertido en uno de los aspectos con mayor relevancia en la vida, como lo son, mercados financieros, el clima, la salud, el trabajo, el tráfico, la demanda de clientes, para ello existen herramientas de predicción con diferentes enfoques.

Debido a la importancia de reducir riesgos y prevenir situaciones desfavorables, la prevención toma un papel relevante para las organizaciones las cuales enfatizan en la tarea de identificar alternativas innovadoras para lograrlo, ya que de ello depende el cumplimiento de sus objetivos previamente planeados, así como la eficaz y eficiente gestión de la cadena de suministro, con base a lo anterior, y considerando la revolución tecnológica actual, inmersa en el impacto y desarrollo sin precedentes de la IA, múltiples empresas hoy en día optan por la explotación de sus datos con fines de pronóstico y predicción con alta precisión.

Lo anterior, considerando su apoyo en la toma de decisiones asertivas, optimización y aprovechamiento de los recursos, contar con estándares altos de calidad, generar estrategias, proyectar ventas o servicios, realizar inversiones, expandir el mercado, diversificar productos o servicios, reducir costos, y anticiparse a los eventos que impidan o retrasen las actividades encaminadas a satisfacer la demanda requerida por los clientes (Hernández, 2022).

Una de las áreas en la que se ha puesto mayor énfasis para la explotación de datos, es el sector salud, ya que en México y en el mundo, las condiciones socioeconómicas, el acceso a servicios de salud, factores ambientales y de salud pública, edad, COVID-19 e impacto, han incrementado la vulnerabilidad de las personas ante las enfermedades de manera significativa, lo que ha obligado a la industria encargada de brindar salud, a desarrollar y mejorar métodos, procesos, procedimientos, crear e implementar tecnología, innovar, realizar grandes inversiones, etc., con el objetivo de atender todas las necesidades y requerimientos,

tomando en cuenta que la salud es una prioridad y un tema indispensable a nivel global (Vanegas, 2020).

Por tal motivo, desde dicha asistencia sanitaria hasta las finanzas, la IA ha sido protagonista de la revolución en el mundo digital actual, basado en una serie de tecnologías disruptivas que están cambiando la forma en que funciona la sociedad y las empresas, estas tecnologías, que incluyen la realidad virtual, blockchain, y especialmente la IA, han provocado un auge tecnológico sin precedentes remodelando sectores, convirtiéndose en un elemento fundamental para cualquier organización que desee mantenerse competitiva, para sobrevivir y prosperar en esta era de cambio constante, las empresas deben adaptarse, un proceso que trae consigo desafíos, limitaciones y retos, pero también enormes oportunidades (Trillo, 2023).

Considerando que se vive en la era de la información y que hoy en día cualquier dispositivo es capaz de generar datos y registrarlos, el presente trabajo consiste en desarrollar un sistema inteligente predictivo de la demanda de insumos para la Institución encargada de brindar Salud y Seguridad Social en la República Mexicana, utilizando las técnicas de ciencia de datos, denotando que ha tenido un crecimiento exponencial en los últimos años, teniendo como objetivo explotar los datos históricos, y con base en los resultados, obtener la ventaja competitiva que impulse el cumplimiento de los objetivos, ya que el abastecimiento que realiza la Institución está destinado a más de 70 millones de usuarios, razón por la cual es de vital importancia ejecutar una eficiente gestión de la demanda para atender las necesidades de salud.

Actualmente el indicador de abastecimiento de la Institución está por debajo del 75% de eficiencia en el suministro de insumos (medicamentos), el cual está por debajo de lo establecido en los objetivos, lo que ha originado una serie de problemáticas para el Instituto, relacionadas con: adquisición de insumos a precios elevados, incremento en los costos de almacenamiento y de mantener derivado del lento o nulo movimiento de los insumos, sobre inventarios, pérdida de bienes por caducidades, robo, saturación de espacios para almacenar, incremento en niveles de mortalidad, baja calidad de vida en usuarios, tratamientos interrumpidos, entre algunos otros, lo cual muestra un panorama de oportunidad de mejora, principalmente en los cálculos de pronósticos de demanda.

El objetivo del estudio consiste en desarrollar una estrategia tecnológica inteligente para predecir la demanda de medicamentos por estado de la república mexicana mediante RNA, ya que cada una de las áreas involucradas en el proceso de cadena de suministro, dependen de los resultados de dicha estimación, por lo tanto, el desarrollo de la herramienta tecnológica tendrá un impacto global en la cadena de suministro del Instituto.

1.2 Apartados de la Tesis

El primer capítulo de este trabajo presenta la información introductoria necesaria para comprender el contexto general del estudio, en él se abordan los antecedentes que dieron origen al proyecto, describiendo la problemática existente dentro de la Institución perteneciente a la industria farmacéutica, así como los factores que motivaron el desarrollo de un sistema de apoyo a la gestión de la demanda de medicamentos, asimismo, se expone el planteamiento del problema, la justificación que sustenta la relevancia del estudio, los objetivos generales y específicos, y finalmente, la delimitación y el alcance del sistema propuesto, con el fin de definir los límites conceptuales, operativos y tecnológicos del proyecto.

El segundo capítulo aborda el marco teórico y conceptual que fundamenta el desarrollo del trabajo, en esta sección se analizan los conceptos relacionados con los pronósticos y los diferentes tipos de modelos predictivos, así como las metodologías y enfoques estadísticos que pueden emplearse para estimar la demanda futura de medicamentos, de igual forma, se incluye una descripción detallada de la ciencia de datos, sus áreas de aplicación, las herramientas tecnológicas empleadas en la actualidad y las técnicas de análisis más relevantes utilizadas en el ámbito de la predicción, finalmente, se presentan y discuten algunos trabajos previos y proyectos relacionados, lo que permite establecer un punto de comparación y referencia para la presente investigación.

Por su parte, los capítulos III y IV describen de manera detallada el proceso metodológico seguido para el desarrollo del sistema inteligente, en el capítulo III se explica la metodología adoptada, las etapas de análisis y diseño, así como la preparación y procesamiento de los datos utilizados, en el capítulo IV, se documenta la implementación práctica del sistema, mostrando los resultados obtenidos, los análisis de desempeño y las pruebas realizadas para validar la funcionalidad y precisión del modelo predictivo propuesto.

1.3 Planteamiento del problema

La gestión de la cadena de suministro en la organización constituye un proceso integral y estratégico, que abarca desde la adquisición de los insumos hasta su entrega final en los distintos puntos de destino, este proceso global involucra una serie de áreas interconectadas que aportan valor de manera proporcional y coordinada, contribuyendo cada una al cumplimiento de los objetivos institucionales, en conjunto, estas áreas conforman un sistema complejo que busca alcanzar un indicador de abastecimiento de la demanda del 95% como mínimo, garantizando así la disponibilidad oportuna de medicamentos e insumos médicos para la atención de la población.

Dentro de este sistema, el pronóstico de la demanda representa el punto de partida esencial para la correcta ejecución de las actividades logísticas y operativas, la precisión en las estimaciones es un factor determinante, ya que de ella depende la planeación interna y externa de los recursos, la proyección de procesos y procedimientos, así como la definición de estrategias operativas y financieras, a partir de los resultados de la estimación de la demanda, se establecen las necesidades de adquisición, se programan los volúmenes de almacenamiento, y se determinan los requerimientos de capital de trabajo, así como la utilización óptima de instalaciones, maquinaria y equipo.

De esta forma, un cálculo de pronóstico preciso no solo favorece la eficiencia logística y la optimización de recursos, sino que también incide directamente en el nivel de servicio al usuario final, garantizando el cumplimiento de los estándares institucionales y la sostenibilidad operativa del sistema, en consecuencia, la gestión efectiva de la cadena de suministro depende en gran medida de la capacidad de anticipar la demanda real, lo que convierte al pronóstico en un elemento estratégico clave dentro de la toma de decisiones en todos los niveles de la organización.

El modelo estándar que utiliza la institución para estimar la demanda es mediante un promedio simple, considerando que los resultados de dichas estimaciones son el punto de partida para llevar a cabo la mayoría de las actividades de la cadena de suministro, se ha identificado que esta técnica tiene un alto sesgo de incongruencia en base a las proyecciones de demanda contra los resultados reales, teniendo un porcentaje de asertividad en dichas estimaciones por debajo del 75% (Sistema de Abasto, 2024).

Por tal motivo, y derivado del bajo rendimiento en los pronósticos por estado, se generan diversas problemáticas que afectan directamente los niveles de abastecimiento de insumos en los distintos puntos donde el Instituto brinda atención médica y social, esta situación repercute directamente en los niveles de servicio, provocando desabastos o sobre abastecimientos que elevan los costos operativos y comprometen la disponibilidad oportuna de los productos necesarios para la atención de los usuarios.

A su vez, la imprecisión en los pronósticos ocasiona compras innecesarias, afectando la distribución equitativa de los recursos y generando escasez de otros insumos prioritarios, lo que impacta directamente en el aprovechamiento de los recursos financieros de la institución, en consecuencia, estos errores influyen negativamente en la calidad de vida de los usuarios, resaltando la necesidad de implementar modelos de predicción más precisos y eficientes que permitan mejorar la planeación y gestión de la cadena de suministro.

1.4 Justificación

Un aspecto fundamental para que la Institución logre una gestión eficiente de las actividades dentro de la cadena de suministro es la mejora de los pronósticos de demanda, los cuales constituyen una pieza clave en la toma de decisiones estratégicas y operativas, estos pronósticos permiten trazar objetivos y metas claras, así como gestionar de manera adecuada los recursos materiales, financieros y humanos necesarios para garantizar la continuidad del servicio, además, influyen directamente en la planificación de requerimientos de materia prima, presupuestos, inversiones, infraestructura, controles operativos, proyectos, personal, maquinaria y equipo, buscando siempre que dichos elementos se mantengan en niveles óptimos para satisfacer las necesidades de los usuarios en tiempo, forma y calidad.

Para este Instituto, reducir la incertidumbre entre la demanda estimada y la demanda real representa uno de los mayores retos organizacionales, ya que de ello depende el cumplimiento de sus indicadores de abastecimiento y la satisfacción de los usuarios, no obstante, la retroalimentación constante de los datos históricos de consumo ha permitido avanzar hacia la optimización de los modelos de proyección de demanda, sentando las bases para una gestión predictiva más precisa y confiable, este enfoque no solo busca mejorar los niveles de surtimiento de medicamentos en los diferentes estados de la República, sino también fortalecer la competitividad institucional dentro del exigente sector farmacéutico, mediante el aprovechamiento inteligente de la información como herramienta estratégica para la toma de decisiones.

El presente estudio se basa en la planeación de la demanda de insumos mediante un sistema inteligente predictivo, sustentado en el uso de RNA, este enfoque permitirá que la cadena de suministro opere de manera eficiente, al calcular niveles de inventario óptimos y eliminar aquellos que resulten ociosos o con bajo movimiento, asimismo, el modelo posibilita la proyección de stocks de seguridad con el fin de anticipar variaciones en la demanda, además de establecer niveles

máximos y mínimos de inventario que garanticen un equilibrio entre disponibilidad y costo.

Con esta metodología, se busca prevenir daños en los insumos, evitar pérdidas por caducidad y reducir significativamente los costos de operación, mantenimiento y almacenamiento, contribuyendo así a una mayor estabilidad y eficiencia financiera dentro de la organización, en conjunto, la implementación del sistema inteligente no solo optimiza los procesos logísticos, sino que también fortalece la capacidad institucional para responder oportunamente a las necesidades del mercado y de los usuarios finales.

Dicho lo anterior, resulta fundamental desarrollar e implementar un sistema inteligente predictivo, ya que este permitirá mejorar de manera significativa la precisión de los pronósticos de demanda, el sistema posee la capacidad de realizar predicciones en tiempo real, integrando procesos automatizados que generan respuestas inmediatas y oportunas, además, puede procesar grandes volúmenes de datos simultáneamente, lo que evidencia su alto potencial tecnológico y su capacidad para aprovechar al máximo la información disponible, transformándola en conocimiento útil para la toma de decisiones estratégicas.

Asimismo, la aplicación de algoritmos de aprendizaje automático representan una herramienta altamente competitiva, capaz de modelar fenómenos complejos y comportamientos no lineales en la demanda de medicamentos, en este contexto, la implementación de RNA en el desarrollo del modelo predictivo proporciona una mayor capacidad de detección de patrones, flexibilidad en el manejo de datos y precisión en los resultados obtenidos, además, estas redes ofrecen la posibilidad de adaptarse dinámicamente a nuevas tendencias, aprender de forma continua a partir de los datos históricos y escalar los procesos analíticos sin perder exactitud en las estimaciones, estas características hacen del sistema predictivo una herramienta esencial para fortalecer la gestión estratégica del Instituto, orientada hacia una planeación más eficiente.

1.5 Objetivo general

Desarrollar un sistema predictor inteligente de la demanda de medicamentos para apoyar la toma de decisiones y optimizar el abastecimiento de dichos insumos mediante algoritmos de aprendizaje automático.

1.6 Objetivos específicos

- Obtención de datos históricos mediante la plataforma en la que actualmente se almacenan las bases de datos en la organización, para procesarlos con la metodología CRISP-DM.
- Realizar limpieza y transformación de datos para incrementar el nivel de precisión de los distintos modelos.
- Desarrollar modelos mediante distintas técnicas para efectuar un análisis comparativo de su rendimiento e identificar el mejor desempeño en la estimación de la demanda de medicamentos por estado.
- Evaluar el rendimiento de los modelos, a través de las métricas.
- Identificar el modelo óptimo para estimar la demanda de medicamentos en la Institución.

1.7 Delimitación y Alcance

El presente trabajo se desarrolla en el área de Planeación de la Demanda de la Institución, enfocándose específicamente en la estimación de los insumos requeridos por el Instituto, es decir, en la generación de pronósticos de demanda, en este contexto, todos los datos, procesos, procedimientos y variables necesarias para el diseño y desarrollo del sistema inteligente predictivo fueron obtenidos en dicha área, garantizando la validez y confiabilidad de la información utilizada, esta dependencia resulta estratégica dentro de la organización, ya que de sus proyecciones depende la correcta planeación de compras, almacenamiento, distribución y suministro de insumos en todas las unidades médicas del país.

Los insumos gestionados por el Instituto se clasifican en distintos grupos de bienes esenciales, tales como medicamentos, material de curación, vacunas, equipo de operación, equipo de protección personal y artículos de aseo, sin embargo, el grupo de medicamentos representa más del 75% del total del suministro nacional, tanto en volumen como en impacto económico y operativo, por esta razón, el estudio se delimita exclusivamente a este grupo, al ser el de mayor relevancia y complejidad dentro de la cadena de suministro.

Asimismo, el Instituto cuenta con una estructura logística descentralizada, conformada por un almacén general y sub-almacenes distribuidos en los 32 estados de la República Mexicana, la ubicación de cada uno de estos almacenes se determina considerando factores como la densidad poblacional, ubicación geográfica, conectividad, infraestructura y niveles históricos de demanda, con el fin de garantizar una cobertura equitativa y eficiente, estos centros de almacenamiento tienen la responsabilidad de suministrar medicamentos e insumos a los hospitales y unidades médicas de cada entidad federativa, por ello, los resultados obtenidos en la proyección de la demanda mediante el modelo propuesto tienen un alcance nacional, permitiendo optimizar el abastecimiento, reducir costos logísticos y mejorar los niveles de servicio en todo el sistema de salud del Instituto.

2 CAPÍTULO II

2.1 Estado del Arte

Se realizó revisión de literatura relacionada con el desarrollo de modelos basados en técnicas de aprendizaje automático para predecir la demanda de insumos requeridos en la industria farmacéutica, evaluación del rendimiento y precisión, a continuación, se exponen algunos trabajos por su relevancia:

Pilatuña-Moncayo (2021), mediante la técnica de regresión lineal múltiple, desarrollaron un modelo para estimar el consumo de medicamentos genéricos de mayor demanda en un distrito de salud, en donde se obtuvo como resultado un coeficiente de determinación de 0.78, para predecir la demanda de medicamentos en una empresa farmacéutica, gestionar inventarios, satisfacer los requerimientos y minimizar los costos de mantenimiento y de almacenamiento, Albarrán-Aguirre-Badillo (2022), mediante las técnicas ARIMA y RNA desarrollaron dos modelos de predicción, obteniendo un error cuadrático medio de: ARIMA: 15,622.52, redes neuronales: 6,999.81, y error absoluto medio: ARIMA: 12,623.33, redes neuronales: 3,695.07, por lo tanto el modelo se puede considerar con baja eficiencia.

Rain-Gigliola (2021), desarrollaron modelos de predicción de ventas para generar un aporte a la gestión de inventarios en una farmacia, mediante técnicas con medias móviles simples, ARIMA, Prophet y Prophet forzado, en donde los resultados para el error de porcentaje medio absoluto indicaron lo siguiente: Medias móviles simples: 46.5%, ARIMA: 48.3%, Prophet: 59.2%, Prophet forzado: 300.1% y modelo actual: 43.9%.

Rea-Gabriela (2020), desarrollaron modelos de predicción de ventas para un laboratorio farmacéutico, basado en las técnicas de ARIMAX, redes neuronales y Holt-winters, los cuales arrojaron como resultado de precisión lo siguiente: ARIMAX: 1.22%, redes neuronales: -0.61% y Holt-winters: -0.56%, en donde el modelo realizado con la técnica de ARIMAX tiene mejores resultados de precisión para el laboratorio.

Para pronosticar la demanda de medicamentos de una farmacia, Vilchez (2023), desarrolló una red neuronal, teniendo como resultado un coeficiente de determinación de 0.9 y un error porcentual medio absoluto de 17.88%.

Angulo-Soto (2021), desarrollaron 6 modelos para predecir volúmenes operacionales de las líneas de negocio de una farmacia, basados en las técnicas de regresión lineal, árboles de decisión en regresión, Random Forest, regresión Ridge, regresión Lasso y regresión Elastic Net, obteniendo un coeficiente de determinación de la siguiente manera: regresión lineal: 73.14%, árboles de decisión en regresión: 73.14%, Random Forest: 72.76%, regresión Ridge: 72.71%, regresión Lasso: 72.75%, y regresión Elastic Net: 72.75%, teniendo a los modelos de regresión lineal y árboles de decisión en regresión como óptimos, sin embargo, se consideran con baja eficiencia.

Mediante las técnicas de ARIMA, Holt-Winters, Series de tiempo exponenciales, Theta, ARHOW y Naive, Siddiqui-Azmat-Ahmed-kummer (2021), proponen el desarrollo de modelos híbridos de previsión de la demanda para la industria farmacéutica, arrojando como resultado un error porcentual absoluto medio de: ARIMA: 5.64, Holt-Winters: 9.37, Series de tiempo exponenciales: 6.33, Theta: 6.21, ARHOW: 1.99 y Naive: 9, que para este estudio, el modelo ARHOW es el que presenta un mayor rendimiento en la estimación de la demanda.

Para predecir las necesidades de medicamentos en el sector farmacéutico, Sujatha-Alekhy (2022), desarrollaron modelos de predicción basados en las técnicas de Regresión lineal, Random forest y RNA, los cuales obtuvieron un coeficiente de determinación de la siguiente manera: Regresión lineal: 0.74, Random forest: 0.74 y RNA: 0.55.

Yanto-Arlis-Putra-Syahputra-Ariandi (2023), desarrollaron un modelo de análisis predictivo de demanda de medicamentos para la industria farmacéutica, basado en la técnica de regresión lineal múltiple, el cual arrojó como resultado un coeficiente de correlación de 0.952 y un coeficiente de determinación de 0.907.

Para pronosticar los tiempos de entrega de compras en una cadena de suministro farmacéutica, Oliveira- Zucchi- Lippi- Lippi- da Silva- Iori (2023), desarrollaron modelos de predicción con las técnicas de Regresión lineal, Máquina de soporte vectorial, Random forest, K-vecinos más cercanos y Perceptrón multicapa, en donde se obtuvieron un error cuadrático medio de la siguiente manera: Regresión lineal: 4.67, Máquina de soporte vectorial; 1.89, Random forest; 3.07, K-vecinos más cercanos: 3.72, y Perceptrón multicapa: 7.84.

Rekabi-Sazvar-Goodarzian (2023), desarrollaron modelos para una red de cadena de suministro farmacéutica, basada en las técnicas de regresión lineal y regresión cuadrática, obteniendo un coeficiente de determinación de la siguiente manera: Regresión lineal: 0.2334, y Regresión cuadrática: 0.6668.

Zahra-Putra (2019), realizaron el desarrollo de modelos para predecir las necesidades de medicamentos con las técnicas de ARIMA y Suavizado exponencial, en donde el error de porcentaje medio absoluto arrojó lo siguiente: ARIMA: 13%, Suavizado exponencial: 14%, y para el error cuadrático medio: ARIMA: 283.715, y Suavizado exponencial: 309.525.

Para estimar las ventas de una farmacia Poyraz-Gürhanli (2020), desarrollaron modelos de predicción implementando las técnicas de Regresión lineal, Procesos Gaussianos, SMOreg, M5P, Random forest, Perceptrón multicapa y M5Rules, obteniendo como resultado un error cuadrático medio como a continuación se detalla; Regresión lineal: 32.9555, Procesos Gaussianos: 32.3981, SMOreg: 33.7522, M5P: 33.6094, Random forest: 41.1429, Perceptrón multicapa: 42.388 y M5Rules: 32.7854.

Así mismo, se revisaron modelos desarrollados con base a las técnicas de aprendizaje profundo, su evaluación de rendimiento, como a continuación se detalla:

Para evitar el deterioro del material y reducir los problemas de almacenamiento de medicamentos en la industria farmacéutica, Mousa-Khateeb (2023), desarrollaron modelos de predicción de suministro, basados en las técnicas de RNN, Long short-term memory, bidireccional Long short-term memory y Gated Recurrent Unit, los cuales alcanzaron un error cuadrático medio de: 0.019, 0.027, 0.024, y 0.028, respectivamente.

Saranani-Dahiya-Geeta-Khan-Nagina (2024), desarrollaron modelos de pronósticos de ventas para la industria farmacéutica, mediante las técnicas de Random forest, Gradient Boosting, Long Short-Term Memory, y ARIMA, obteniendo un error medio absoluto como a continuación se describe: Random forest: 1,000, Gradient Boosting: 950, Long Short-Term Memory: 900, y ARIMA: 1,100, y un error cuadrático medio: Random forest: 15,000, Gradient Boosting: 14,000, Long Short-Term Memory: 13,000, y ARIMA: 16,000.

Kumar-Waghmare-Bukya-Depuru-Kaliamoorthy (2023), a través de las técnicas de RNN, redes neuronales recurrentes bidireccionales, Long Short-Term Memory, Bidirectional Long Short-Term Memory, Gated Recurrent Unit, Bidirectional Gated Recurrent Unit y Gradient Boost, desarrollaron modelos para estimar la demanda de medicamentos para una atención médica óptima, obteniendo como resultado un error porcentual medio absoluto para uno de los medicamentos analizados de la siguiente manera: RNN: 21.8, Redes neuronales recurrentes bidireccionales: 69, Long Short-Term Memory: 81.8, Bidirectional Long Short-Term Memory: 76.8, Gated Recurrent Unit: 78.8, Bidirectional Gated Recurrent Unit: 67.8, y Gradient Boost: 1.98.

Rahman-Yoganandan (2022), desarrollaron modelos de previsión de la demanda en la industria farmacéutica mediante las técnicas de ARIMA, Radial Basis Function, Generalized Regression Neural Network, Probabilistic Neural Network, Long Short-Term Memory y Stacked Long Short-Term Memory, en donde se obtuvieron los siguientes resultados para una raíz del error cuadrático medio; ARIMA: 15.50, Radial Basis Function: 6.59, Generalized Regression Neural Network: 6.01, Probabilistic Neural Network: 6.21, Long Short-Term Memory: 15.86 y Stacked Long Short-Term Memory: 16.22.

Posterior a la revisión, se puede observar que dichas herramientas han tenido una evolución y amplia participación en la gestión de la cadena de suministro en las empresas, ya que han logrado impulsar la eficiencia y eficacia de las áreas de la organización.

La reducción de costos de operación, optimización de procesos y procedimientos, la entrega en tiempo y forma de los insumos, incremento de los índices de abastecimiento, asertividad en la toma de decisiones, aprovechar al máximo los recursos, son algunas de las mejoras que ha traído consigo la implementación de los modelos inteligentes de predicción.

A lo largo de los trabajos revisados, se pueden identificar distintas técnicas implementadas para el desarrollo de los modelos de estimación de la demanda, tales como: Regresión lineal, Redes neuronales, ARIMA, ARIMAX, Random forest, ARHOW, Medias móviles simples, entre algunas otras, de las cuales en la mayoría de los casos los modelos desarrollados bajo las técnicas de regresión lineal y redes neuronales presentan un mejor rendimiento.

La revisión de literatura realizada permitió identificar un panorama amplio y actualizado sobre el uso de técnicas de aprendizaje automático y modelos estadísticos para la predicción de la demanda, ventas y necesidades de insumos dentro de la industria farmacéutica, los estudios analizados evidencian que, en los últimos años, diversas organizaciones y autores han recurrido a modelos basados en regresión, métodos híbridos, RNA y modelos de aprendizaje profundo, con el objetivo de optimizar la gestión de inventarios, mejorar la eficiencia operativa y fortalecer la toma de decisiones en la cadena de suministro farmacéutica.

Los trabajos consultados permiten observar que no existe un modelo universal, ya que el desempeño depende del tipo de insumos, el lugar, el periodo de análisis, la disponibilidad y calidad de los datos, así como de las características propias de cada organización, no obstante, se aprecia una tendencia consistente: los modelos de regresión son los que con mayor frecuencia alcanzan un mejor rendimiento, especialmente cuando se evalúan mediante métricas como el error cuadrático medio, coeficiente de determinación y MAPE.

Asimismo, se identifica que muchos de los modelos desarrollados aún presentan niveles de eficiencia moderados o bajos, lo cual abre oportunidades para mejorar la precisión mediante el uso de técnicas más avanzadas, integración de nuevas variables, modelos híbridos o enfoques basados en aprendizaje profundo, también se evidencia que el desempeño de los modelos varía considerablemente entre estudios, debido a diferencias en los horizontes temporales, los tipos de productos, la estacionalidad, la metodología de limpieza de datos y los objetivos específicos de cada caso.

Posterior a esta revisión, se puede afirmar que se han explorado y comparado distintos tipos de modelos aplicados específicamente en la industria farmacéutica, tanto para la estimación de demanda como para la predicción de ventas, compras y tiempos de entrega, estos modelos han sido implementados principalmente con el propósito de respaldar y validar la gestión de la cadena de suministro, buscando garantizar la disponibilidad oportuna de medicamentos y optimizar los procesos internos de abastecimiento.

Finalmente, el análisis evidencia que la adopción de IA dentro de las organizaciones farmacéuticas representa una herramienta estratégica para efficientar la estimación de la demanda, reducir costos, incrementar los niveles de servicio y mejorar la planeación operativa, sin embargo, también revela que aún existe una importante área de oportunidad para estandarizar metodologías, mejorar la calidad de los datos y desarrollar modelos robustos y estables, capaces de adaptarse a la variabilidad intrínseca del sector farmacéutico.

2.2 Marco Teórico

Cadena de suministro

Está definida como la serie relacionada de actividades que se ocupa de la planificación, coordinación y control de materiales, piezas y productos terminados desde los proveedores hasta el cliente (Santos, 2023).

Objetivo de la cadena de suministro

El valor que una cadena de suministro genera es la diferencia entre lo que vale el producto final para el cliente y los costos en que la cadena incurre para cumplir la petición de éste, influye directamente en la rentabilidad de la empresa al propiciar desempeños ordenados y articulados o servicios que conllevan a ofrecer a los clientes productos requeridos en un entorno de racionalización de costos, mediante procesos de negocios eficaces y eficientes, impactando en los ingresos de la empresa (Banda, 2022).

Demanda

La demanda está definida por lo que los consumidores desean adquirir o están dispuestos a comprar, basados en las necesidades ya sea de bienes o servicios en un determinado mercado de una economía (Inzunza, 2020).

Inventarios

Los inventarios o stocks son la cantidad de bienes que una empresa mantiene en existencia en un momento dado, bien sea para la venta ordinaria del negocio o para ser consumidos en la producción de bienes o servicios para su posterior comercialización (Ramos, 2022).

Pronóstico

Un pronóstico es una predicción de uno o más eventos futuros a partir de indicios, el nivel de éxito de un pronóstico radica en la exactitud con la que coincide con la realidad (Saucedo, 2022).

Pronóstico de demanda

El pronóstico de la demanda es el proceso de predecir o estimar qué productos o servicios serán requeridos por los consumidores en un determinado periodo de tiempo, por lo tanto, consiste en desarrollar proyecciones futuras, para así estar preparados para abastecer las necesidades del mercado (Saucedo, 2022).

Clasificación de los pronósticos

De corto plazo (máximo 3 meses): Son más precisos que los de mediano y largo plazo, se utilizan en las empresas principalmente para tomar decisiones (Fernández, 2020).

De mediano plazo (de 3 meses a 3 años): Se utilizan en la planificación para la elaboración de presupuestos, estimando las ventas y flujos de efectivo (Fernández, 2020).

De largo plazo (más de 3 años): Se utilizan para predecir las ventas de nuevos productos, las ganancias de la introducción de nuevas tecnologías, o bien los beneficios de la expansión a nuevos mercados (Fernández, 2020).

Métodos para pronosticar

Cualitativos: Los métodos cualitativos son principalmente subjetivos y se apoyan en el juicio humano, son apropiados sobre todo cuando la información histórica no está disponible o existen muy pocos datos; o bien, cuando los expertos cuentan con resultados de investigación del mercado que pueden afectar el pronóstico (Fabian, 2022).

Cuantitativos: Los métodos cuantitativos manejan un modelo matemático fundamental para llegar a un pronóstico, el supuesto básico de todos los métodos cuantitativos de pronóstico es que los datos históricos y los patrones de los datos son instrumentos de predicción confiables del futuro (Fabian, 2022).

Series de tiempo: Los métodos de pronóstico de series de tiempo utilizan el comportamiento histórico de la demanda para estimar valores futuros y generar pronósticos más precisos, se basan en la suposición de que la historia de la demanda pasada es un buen indicador de la demanda futura, estos métodos son apropiados cuando el patrón de la demanda básica no varía significativamente de un año al siguiente (Sosa, 2020).

Medidas del error del pronóstico

Un buen método de pronóstico debe captar el componente sistemático de la demanda, pero no el aleatorio, este último se manifiesta en sí mismo en la forma de un error de pronóstico, el cual contiene información valiosa que debe analizarse con sumo cuidado, y existen diferentes tipos, como a continuación se describen:

Error cuadrático medio

El error cuadrático medio (MSE, por sus siglas en inglés), es otro método para evaluar una técnica de pronóstico, cada error se eleva al cuadrado; luego, se suman y se dividen entre el número de observaciones, este método penaliza los errores grandes de pronóstico debido a que los errores se elevan al cuadrado (Salgado, 2022).

$$MSE = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}$$

Donde:

Y_t : valor real observado en el periodo t .

$\hat{Y}_t$: valor estimado o pronosticado por el modelo en el periodo t .

n : número total de observaciones analizadas.

t : periodo o instante de tiempo evaluado.

Error absoluto medio

Es otra forma de evaluar la calidad de los modelos de regresión, al igual que el error cuadrático medio, el error absoluto medio (MAE, por sus siglas en inglés), permite medir la diferencia entre los valores pronosticados por un modelo y los valores reales observados, la principal característica es que calcula el promedio de los errores absolutos, es decir, sin considerar si el error es positivo o negativo, lo que facilita interpretar qué tan alejadas están, en promedio, las predicciones respecto a los datos reales. (Villegas, 2023).

$$MAE = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n}$$

Donde:

Y_t : valor real observado en el periodo t .

$\hat{Y}_t$: valor estimado o pronosticado por el modelo en el periodo t .

n : número total de observaciones analizadas.

t : periodo o instante de tiempo evaluado.

$|Y_t - \hat{Y}_t|$: valor absoluto del error entre el dato real y el estimado.

Raíz del error cuadrático medio

El error de raíz cuadrática media (RMSE, por sus siglas en inglés), es una medida utilizada para evaluar la precisión de un modelo de regresión o pronóstico, este indicador representa la desviación estándar de los residuos o errores de predicción, es decir, la diferencia entre los valores reales y los valores estimados por el modelo, los residuos permiten medir qué tan alejados se encuentran los datos reales respecto a la línea de regresión o línea de mejor ajuste, el error de raíz cuadrática media calcula la magnitud promedio de dichos errores, otorgando mayor peso a los errores grandes debido al uso del cuadrado de las diferencias. (García, 2022).

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}}$$

Donde:

Y_t : valor real observado en el periodo t .

$\hat{Y}_t$: valor estimado o pronosticado por el modelo en el periodo t .

n : número total de observaciones analizadas.

t : periodo o instante de tiempo evaluado.

Error porcentual absoluto medio

El error porcentual absoluto medio (MAPE, por sus siglas en inglés), es el error absoluto promedio, expresado como porcentaje de la demanda, se calcula al encontrar el error absoluto en cada periodo, dividiéndolo entre el valor real observado para ese periodo y luego promediando los errores porcentuales absolutos, permite interpretar de manera sencilla qué tan precisas son las predicciones del modelo, ya que muestra el porcentaje promedio de desviación entre los valores reales y los pronosticados. (Kuma, 2023).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100$$

Donde:

Y_t : valor real observado.

$\hat{Y}_t$: valor estimado o pronosticado.

n : número total de observaciones.

MAPE: error medio absoluto porcentual (%).

Coeficiente de determinación

El coeficiente de determinación, es una importante medida de la regresión lineal que representa la parte de variación de la variable dependiente que viene explicada por un conjunto de variables independientes, por lo tanto, mide la capacidad predictiva del modelo estimado, es decir, un coeficiente de determinación igual a 1 significa un ajuste perfecto (Sujatha, 2022).

$$R^2 = 1 - \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

Donde:

Y_t : valor real observado en el periodo t .

$\hat{Y}_t$: valor estimado o pronosticado por el modelo en el periodo t .

$\bar{Y}$: promedio de los valores reales observados.

n : número total de observaciones.

t : periodo o instante de tiempo evaluado.

Inteligencia Artificial (IA)

El concepto de inteligencia artificial no es completamente preciso; sin embargo, en términos generales, se entiende como la capacidad de una máquina para imitar funciones cognitivas propias de la mente humana, tales como el aprendizaje, el razonamiento, la creatividad, la percepción, la comprensión y el uso del lenguaje, un subcampo de la IA que ha ganado auge en años recientes es el aprendizaje automático, donde un sistema aprende a ejecutar tareas, por ejemplo, a partir de datos históricos (Rouhiainen, 2020).

Aprendizaje Automático

Es una disciplina del campo de la IA que, a través de algoritmos, permite a los sistemas computacionales identificar patrones en datos masivos y elaborar predicciones (análisis predictivo), este aprendizaje permite a computadores realizar tareas específicas de forma autónoma. (Ramírez, 2021).

Tipos de aprendizaje

Aprendizaje supervisado: Estos algoritmos se enmarcan en el aprendizaje automático y funcionan mediante la interpretación de relaciones en datos etiquetados, es decir, un conjunto donde cada ejemplo de entrada está asociado a una salida o respuesta conocida, su objetivo es que el modelo aprenda la relación entre las variables de entrada y las salidas correctas, de manera que pueda predecir o clasificar correctamente nuevos datos que no ha visto antes (Arengas Acosta, Guzmán Cabrera, & López Ramírez, 2024).

Aprendizaje no supervisado: Es un tipo de aprendizaje automático en el que el modelo se entrena con un conjunto de datos sin etiquetas, es decir, donde no se conoce la salida o respuesta esperada, el algoritmo analiza las características de los datos y agrupa o representa los elementos según su similitud o comportamiento común, la red no recibe ninguna información por parte del entorno que le indique si la respuesta generada es correcta o no a una determinada entrada, estas redes encuentran las características, correlaciones o categorías que puedan establecer entre los datos de entrada (Moreno Pallares, & Mejía Peñafiel, 2022).

Aprendizaje profundo

Es un subconjunto del aprendizaje automático, que se basa en algoritmos capaces de representar fenómenos de alta complejidad basados en RNA, en otras palabras, el aprendizaje profundo intenta imitar el funcionamiento del cerebro humano, donde las “neuronas” artificiales están organizadas en capas que se comunican entre sí, cada capa transforma la información y extrae características cada vez más complejas, lo que permite que el sistema aprenda a reconocer patrones, clasificar datos, predecir resultados o tomar decisiones (Erick Lambis-Alandete, 2023).

Tipos de algoritmos

Regresión

Tienen el objetivo de crear una metodología para relacionar un criterio cuantitativo y una o más variables objetivo-continuas, cuyos niveles pueden asociarse con una escala, como la temperatura, la humedad, la conductividad eléctrica, la presión, el tiempo, mercados financieros, utilizados principalmente para predecir valores numéricos (Burgh Day & Leeuwenburg, 2023).

Clasificación

Se entiende por clasificación al proceso de aprendizaje matemático estadístico, por medio del cual un algoritmo computacional identifica las características que distinguen categorías o clases de documentos de las demás, esta puede ser llevada a cabo utilizando distintas aproximaciones, tales como clasificación supervisada, no supervisada o semi-supervisada, en particular, los algoritmos de clasificación supervisada son entrenados en un grupo de documentos, categorizados y etiquetados manualmente, acorde a algún criterio particular (tema, materia, origen, género, propósitos, etc.), conformando una clase, de esta manera, el objetivo de estos clasificadores es decidir en qué categoría debe ir cada texto nuevo, partiendo de un conjunto de atributos (caracteres, lexemas, categorías gramaticales, semánticas o una combinación de ellos) para conformar una representación, que permita al algoritmo asignar los documentos al esquema de clasificación previo (Venegas, 2021).

Técnicas para pronosticar

Redes neuronales artificiales (RNA)

Las redes neuronales están inspiradas en las redes neuronales biológicas, las cuales utilizan algoritmos de aprendizaje y tienen un procesamiento no lineal, por lo que la red aumenta su capacidad para aproximar funciones y clasificar patrones, la red está constituida por un gran número de nodos interconectados, cada uno de los cuales recibe una entrada desde otra unidad o fuente externa, donde cada entrada tiene un peso asociado, que se va ajustando durante el proceso de aprendizaje (Albarrán, 2022).

Las RNA se utilizan principalmente para tareas en las que es difícil derivar restricciones lógicas de forma explícita, como el reconocimiento de patrones y el análisis predictivo (Arana, 2021).

Redes neuronales recurrentes (RNN, por sus siglas en inglés)

Este tipo de redes presenta una mayor capacidad para entender y aprender diferentes patrones en los datos de entrada, las RNN no solo incluyen conexiones hacia adelante como las redes neuronales convencionales, sino también conexiones hacia atrás, creando un tipo de retroalimentación, esto le permite exhibir un comportamiento dinámico temporal (Jaramillo Duque, 2022).

Red de memoria a corto-largo plazo (LSTM, por sus siglas en inglés)

Fueron desarrolladas a partir de las RNN, y adicional a su diversidad de aplicaciones, reducen los problemas de dependencia a largo plazo debido a su estructura de unidad de almacenamiento única y ayudan a predecir series de tiempo, las redes LSTM tienen una entrada y una salida adicionales, este elemento se conoce como celda de estado, la cual es la clave del funcionamiento de estas redes, se pueden añadir o remover datos que se desean sacar de la memoria de la red (Herrera Cofre, 2020).

Máquina de soporte vectorial

Es un algoritmo de aprendizaje automático supervisado que se puede utilizar para problemas de clasificación o regresión. Utiliza una técnica llamada truco del núcleo para transformar sus datos y luego, basándose en estas transformaciones, encuentra un límite óptimo entre las posibles salidas (Herrera Cofre, 2020).

Media Móvil Integrada Autorregresiva (ARIMA)

Son una representación matemática (ARIMA, por sus siglas en inglés), de una serie temporal que permite capturar las características de un fenómeno real a partir de la información contenida en los datos y posteriormente generar un pronóstico, basándose únicamente en los datos de entrada (Ayala Castrejón, 2020).

Modelo Autorregresivo Integrado de Media Móvil con Variables Exógenas (ARIMAX)

El modelo (ARIMAX, por sus siglas en inglés), es una extensión del modelo ARIMA tradicional que permite la inclusión de variables adicionales, conocidas como variables exógenas, que pueden tener un efecto en las series temporales a pronosticar (Andrés, 2023).

Holt-Winters

Es uno de los métodos para generar pronósticos que predicen patrones con estacionalidad, siendo éste un modelo de pronóstico estadístico que utiliza promedios ponderados de observaciones pasadas para pronosticar pasos futuros, utiliza los promedios móviles ponderados exponencialmente para actualizar los datos necesarios para ajustar la media (tendencia) y la estacionalidad, construyéndose de forma multiplicativa (Mira Segura, Martínez Cruz, Trejo Martínez, Kryvko, & Dorantes Benavidez, 2024).

ARHOW

Es una combinación de algoritmos basados en las técnicas de ARIMA y Holt-Winters, para pronosticar demanda con una mayor precisión (Siddiqui, Azmat, Ahmed, & Kummerd, 2021).

Bosque aleatorio (Random Forest)

El Random forest es un algoritmo de aprendizaje automático de uso común, que combina la salida de múltiples árboles de decisión para alcanzar un solo resultado, su facilidad de uso y flexibilidad han impulsado su adopción, ya que maneja problemas de clasificación y regresión (Zúñiga, 2020).

Naive Bayes

El algoritmo de Naive Bayes es un clasificador de tipo probabilístico, que determina un grupo de valores con base en la frecuencia, en un determinado conjunto de datos de entrenamiento, tiene como base al Teorema de Bayes, y se asume una independencia entre las variables de entrada (Tito Aco, Hancoco Condori, & Pérez Vera, 2023).

Hiperparámetros

Los hiperparámetros son parámetros ajustables que se eligen para entrenar un modelo y que rigen el propio proceso de entrenamiento, estos valores suelen permanecer constantes durante el proceso de entrenamiento, en escenarios de aprendizaje profundo o aprendizaje automático, el rendimiento del modelo depende en gran medida de los valores de hiperparámetros seleccionados (Muñoz Cañón & Romero Triana, 2021).

Ciencia de Datos

Es la conjunción de matemáticas aplicadas, ciencias computacionales e IA con el fin de explotar datos para construir soluciones y predecir comportamientos, es una herramienta poderosa para aprovechar la gran cantidad de millones de datos que se generan a cada minuto (Jesús García, 2020).

Funcionamiento

1. Un proceso de decisión: en general, los algoritmos de aprendizaje automático se utilizan para hacer una predicción o clasificación, con base en algunos datos de entrada, que pueden estar etiquetados o no etiquetados, su algoritmo producirá una estimación sobre un patrón en los datos.

2. Una función de error: una función de error evalúa la predicción del modelo, si hay ejemplos conocidos, una función de error puede hacer una comparación para evaluar la precisión.
3. Un proceso de optimización del modelo: si el modelo puede ajustarse mejor a los puntos de datos en el conjunto de entrenamiento, entonces los pesos se ajustan para reducir la discrepancia entre el ejemplo conocido y la estimación del modelo, el algoritmo repetirá este proceso iterativo de "evaluar y optimizar", actualizando pesos de forma autónoma hasta que se haya cumplido un umbral de precisión.

Metodología CRISP-DM

CRISP-DM, que son las siglas de Cross-Industry Standard Process for Data Mining, es un método probado para orientar sus trabajos de minería de datos, como metodología, incluye descripciones de las fases de un proyecto, las tareas necesarias en cada fase y una explicación de las relaciones entre las tareas, como modelo de proceso, CRISP-DM ofrece un resumen del ciclo vital de minería de datos (Espinosa, 2020).

Fases de la metodología CRISP-DM

Comprensión del negocio: Inicio del proyecto de minería de datos, entendiendo y comprendiendo el problema que se quiere resolver, estableciendo objetivos y requisitos desde un panorama empresarial hasta un escenario técnico (IBM, 2021).

Comprensión de los datos: Recolección, exploración y entendimiento de los datos (IBM, 2021).

Preparación de los datos: Se seleccionan, limpian y generan datos correctos, para posteriormente organizarlos y prepararlos para la fase de modelado (Sánchez Trujillo, 2021).

Modelado: Fase que tiene como objetivo principal seleccionar, diseñar, construir y elegir un algoritmo para entrenar el modelo.

Evaluación: En esta etapa se determina la calidad del modelo con base en el análisis de ciertas métricas estadísticas del mismo, comparando los resultados con resultados previos, de acuerdo con los resultados de esta etapa se determina seguir con la última fase de la metodología, regresar a alguna de las etapas anteriores o incluso partir de cero con un nuevo proyecto (Espinosa Zúñiga, 2020).

Despliegue: En esta última etapa, se definen las estrategias de implementación, monitoreo, retroalimentación y mantenimiento del modelo establecido, aquí también es importante documentar los resultados de manera clara para el usuario final y asegurarse de que todas las etapas de la metodología se documenten debidamente para hacer una revisión del proyecto a fin de obtener lecciones aprendidas durante el proceso, asimismo, monitorear las acciones para detectar áreas de oportunidad o incluso nuevos problemas (Espinosa Zúñiga, 2020).

Big Data

El término “big data” abarca datos que contienen una mayor variabilidad y que se presentan en volúmenes crecientes y a una velocidad superior, esto también se conoce como “las tres V” (Oracle, 2024).

Dicho de otro modo, el big data está formado por conjuntos de datos de mayor tamaño y más complejos, especialmente procedentes de nuevas fuentes de datos. Estos conjuntos de datos son tan voluminosos que el software de procesamiento de datos convencional sencillamente no puede gestionarlos. Sin embargo, estos volúmenes masivos de datos pueden utilizarse para abordar problemas empresariales que antes no hubiera sido posible solucionar (Oracle, 2024).

Herramientas de implementación

Python

Es un lenguaje de programación interpretado cuya filosofía hace hincapié en la legibilidad de su código, se trata de un lenguaje de programación multiparadigma, ya que soporta parcialmente la orientación a objetos, programación imperativa y, en menor medida, programación funcional, es un lenguaje interpretado, dinámico y multiplataforma que posee una licencia de código abierto, y permite la integración de varias librerías para la implementación de sistemas de IA (Herrera Ardila & Roncancio Peña, 2022).

Google Colab

Google Colab es una plataforma en línea que permite crear, ejecutar, almacenar y compartir programas en Python. Es un servicio gratuito de Jupyter Notebook que se utiliza para el aprendizaje automático, la ciencia de datos y la educación (Google, 2025).

Keras

Keras es una biblioteca de Redes Neuronales de Código Abierto escrita en Python, es capaz de ejecutarse sobre TensorFlow, Microsoft Cognitive Toolkit o Theano, está especialmente diseñada para posibilitar la experimentación en más o menos poco tiempo con redes de Aprendizaje Profundo, sus fuertes se centran en ser amigable para el usuario, modular y extensible, Keras ha sido concebido para actuar como una interfaz en lugar de ser un frameworks de aprendizaje automático standalone, ofrece un conjunto de abstracciones más intuitivas y de alto nivel haciendo más sencillo el desarrollo de modelos de aprendizaje profundo independientemente del backend computacional utilizado (Herrera Ardila & Roncancio Peña, 2022).

3 CAPÍTULO III

3.1 Metodología

En este apartado se describe el enfoque metodológico empleado para el desarrollo del proyecto, detallando las fases, técnicas y herramientas utilizadas para alcanzar los objetivos planteados en el desarrollo del modelo de predicción, la metodología define el proceso seguido desde la recopilación y preparación de los datos hasta la construcción, evaluación y validación de los modelos predictivos, con el propósito de garantizar la confiabilidad y validez de los resultados obtenidos, así como los próximos pasos a seguir en el proyecto.

3.2 Comprensión del negocio

La institución es responsable de garantizar el servicio de salud y seguridad social a más de 70 millones de usuarios, lo que implica no solo la prestación de atención médica integral, sino también el suministro oportuno de los insumos necesarios para cubrir de manera adecuada sus tratamientos, este proceso representa un eje crítico para el funcionamiento del sistema de salud, ya que la disponibilidad de medicamentos e insumos médicos es determinante para asegurar la continuidad en la atención y la calidad del servicio brindado a los usuarios.

El proceso de suministro inicia en el área de planeación, la cual tiene como función principal la estimación de la demanda de insumos, para ello, se generan proyecciones a través de modelos de pronóstico que permiten anticipar las necesidades de cada entidad federativa, los resultados de dichas proyecciones se comunican a las distintas áreas de la institución, con el objetivo de coordinar de manera eficiente las actividades relacionadas con la cadena de suministro, posteriormente, con base en estas estimaciones, se gestionan las solicitudes de insumos a los proveedores, de modo que se logre atender la demanda proyectada en cada estado.

Como parte de este proceso, la institución contempla la definición de un inventario de seguridad para cada medicamento, equivalente a un rango de entre 2.5 y 3 meses de consumo.

El proceso para suministrar los medicamentos se realiza mediante 2 tipos de red de distribución, dependiendo de la densidad de la población así como la ubicación geográfica de los hospitales y unidades médicas en cada Estado.

A continuación se presenta el primer tipo de diagrama, en el cual se observa la presencia de un almacén central y un sub almacén, este tipo de red de distribución se utiliza principalmente en los estados que concentran un mayor número de usuarios y, en consecuencia, una mayor cantidad de hospitales y unidades médicas, asimismo, resulta apropiado en aquellas entidades donde las distancias entre los hospitales o unidades médicas son considerablemente amplias, ya que su implementación permite reducir los tiempos de entrega y optimizar los costos de traslado, mejorando con ello la eficiencia logística del sistema de abastecimiento.




Diagrama 3.1 Red de distribución de medicamentos tipo A. Fuente: Elaboración propia.

Por otro lado, el siguiente diagrama muestra la segunda forma de red de distribución, la cual representa el modelo utilizado por la institución en la mayoría de los estados, en este esquema se cuenta con un único almacén central, que resulta suficiente para atender la demanda de usuarios existente en cada entidad, considerando tanto el volumen de consumo como las distancias entre los hospitales y unidades médicas, este tipo de red es funcional y eficiente en contextos donde la cobertura geográfica y el número de establecimientos permiten una distribución directa desde un solo punto de abastecimiento.




Diagrama 3.2 Red de distribución de medicamentos tipo B. Fuente: Elaboración propia.

3.3 Objetivos de la organización

Garantizar el suministro de medicamentos en cada uno de los estados de la república, y a su vez, en cada hospital y clínica, con el objetivo de atender las necesidades de los usuarios en tiempo y forma de manera eficiente y oportuna.

3.4 Evaluación de la situación actual

El proceso para llevar a cabo la estimación de la demanda de medicamentos en el área y proceso de abastecimiento, es el siguiente:




Diagrama 3.3 Diagrama de flujo para el cálculo de pronóstico actual. Fuente: Elaboración propia.

Actualmente, la institución realiza la predicción de la demanda de medicamentos mediante el uso de un promedio simple, considerando para la mayoría de los insumos el histórico de 12 periodos, mientras que en algunos casos específicos se emplea un horizonte de 6 periodos, posteriormente, las proyecciones generadas se evalúan a través de un análisis de congruencia, comparando lo estimado con los requerimientos reales consumidos, como resultado de este procedimiento, se ha identificado que el nivel de asertividad en los cálculos es inferior al 75%, lo que evidencia la necesidad de implementar métodos de pronóstico más robustos y precisos.

Es importante resaltar que de dichos resultados, depende en gran medida que los usuarios reciban el surtimiento de los insumos necesarios para llevar a cabo los tratamientos correspondientes y atender el surtimiento de recetas, así mismo, estos cálculos son transmitidos a las demás áreas, con el objetivo de implementar los análisis pertinentes y desarrollar las proyecciones necesarias para llevar a cabo la gestión de la cadena de suministro.

3.5 Objetivos del proyecto

El objetivo general de esta investigación es desarrollar un sistema predictor inteligente de la demanda de medicamentos que, a través de la implementación de algoritmos de aprendizaje automático, permite realizar estimaciones precisas y oportunas del consumo, dicho sistema tendrá como propósito principal apoyar la toma de decisiones en la planeación estratégica y operativa, contribuyendo así a la optimización de los procesos de abastecimiento, garantizar la disponibilidad de insumos en hospitales y unidades médicas, reducir riesgos de desabasto, y aprovechar al máximo los recursos.

3.6 Planificar el proyecto

Mediante la metodología CRISP-DM, se desarrolló el proyecto a través de las siguientes etapas: Comprensión del negocio, Comprensión de los datos, Preparación de los datos, Modelado, Evaluación y Despliegue.

3.7 Comprensión de los datos

En esta fase se lleva a cabo la recolección inicial de los datos que servirán como base para el desarrollo del proyecto, el proceso comprende la recopilación, descripción, exploración y evaluación de la calidad de la información disponible, con el fin de identificar su pertinencia, consistencia y confiabilidad, esta etapa resulta fundamental, ya que los datos constituyen el punto de partida del trabajo y, en gran medida, determinan el desempeño y la precisión de los modelos de predicción, asimismo, en esta fase se analizan posibles problemas asociados a la información, tales como valores faltantes, duplicados, inconsistencias o sesgos, con el objetivo de establecer las acciones necesarias para su depuración y garantizar una base sólida para las siguientes etapas del proyecto.

3.8 Recolección de datos iniciales

Los datos históricos correspondientes al consumo de medicamentos se encuentran almacenados en el sistema ERP institucional, el cual concentra la información operativa y administrativa relacionada con la gestión del abasto y distribución de insumos médicos, dichos datos son consultados y extraídos mediante la utilización del lenguaje SQL, a través de consultas personalizadas que permiten filtrar la información según diversas variables, tales como día, mes, año, destino de entrega, tipo de medicamento y precio, entre otras.

Cabe mencionar que las consultas pueden ser ejecutadas bajo dos niveles de desagregación, el primer nivel corresponde al consumo detallado por hospital y unidad médica, lo que permite un análisis más granular y preciso de la demanda en cada centro de atención, el segundo nivel, en cambio, agrupa la información a nivel estatal, representando la sumatoria total de los consumos registrados en los hospitales y las diferentes unidades médicas del estado, reduciendo así el número total de registros y facilitando el procesamiento de la información en etapas posteriores del análisis.

Para el desarrollo del presente trabajo se optó por emplear la información del segundo nivel, correspondiente a los consumos agregados por estado, ya que este enfoque permite una visión integral del comportamiento de la demanda a nivel regional y facilita la aplicación de los modelos predictivos, la información utilizada comprende el periodo entre 2020 y 2025, datos que permiten identificar tendencias, patrones estacionales y variaciones significativas en el consumo de medicamentos dentro del sistema institucional.

3.9 Descripción de los datos


A continuación, se describe a qué se refiere cada una de las variables, así como el tipo de dato obtenido:

Variable	Tipo	Descripción
Clave de destino	Numérica	Es una clave única que está compuesta por 12 caracteres, la cual se asigna a cada uno de los destinos para identificarlos de manera numérica.
Destino	Texto	Es el lugar donde se tiene el consumo de medicamentos, y en donde se tienen que abastecer los insumos necesarios para realizar la distribución a nivel hospital y unidad médica con los que cuentan los siguientes destinos; Aguascalientes, Baja California Norte, Baja California Sur, Campeche, Nuevo León, Ciudad de México, Chiapas, Chihuahua, Coahuila, Colima, Durango, Guanajuato, Jalisco, Puebla, Sonora, Veracruz, Yucatán, Guerrero, Hidalgo, Michoacán, Morelos, Nayarit, Oaxaca, Querétaro, Quintana Roo, San Luis Potosí, Sinaloa, Tabasco, Tamaulipas, Tlaxcala, Zacatecas.
Específico	Numérica	Es una clave única, compuesta por 4 caracteres para identificar cada uno de los medicamentos de manera numérica.
Diferenciador	Numérica	Clave compuesta por 2 caracteres, para diferenciar en algunos casos el tipo de presentación de algunos medicamentos, ya que pueden tener 2 o 3 tipos.
Descripción de artículo	Texto	Es el nombre con el que se identifica el medicamento, al igual, puede contener información adicional respecto al tipo de presentación, unidad de medida y tipo de envase o empaque.
Meses	Numérica	Los meses contienen la cantidad de piezas consumidas de medicamentos por cada uno de los destinos, los cuales van de enero a diciembre.

Tabla 3.1 Descripción de las variables. Fuente: Elaboración propia.

3.10 Exploración de los datos


Después de la extracción y explotación de los datos, se tienen los siguientes resultados en la siguiente gráfica muestra la cantidad de datos generados en relación con los consumos de medicamentos durante el periodo 2020–2025, conforme al primer nivel de desagregación, en ella se observa la existencia de un volumen considerable de registros históricos, los cuales constituyen una base de información robusta, esta disponibilidad de datos permite su aprovechamiento mediante modelos de predicción inteligentes, facilitando la estimación de la demanda con mayor precisión, la identificación de patrones de consumo y la mejora en la planeación del abastecimiento, contribuyendo así a una toma de decisiones oportuna.



Gráfica 3.1 Datos generados de consumos de medicamentos por año. Fuente: Elaboración propia


La generación y acumulación de grandes volúmenes de datos en una institución no solo representa un registro histórico, sino que constituye un recurso potencial que, al ser procesado y analizado adecuadamente, permite optimizar la toma de decisiones, contar con información detallada y actualizada, eficientiza la planeación del abastecimiento, reduce riesgos de desabasto, mejora la eficiencia en la distribución y, lo más importante, impacta de manera directa en la calidad del servicio brindado a los usuarios, por lo tanto, la correcta explotación de los datos se convierte en un elemento clave para garantizar la sostenibilidad operativa y la mejora continua de los procesos institucionales.

Los datos generados corresponden a los medicamentos consumidos por año en todo el país, la siguiente gráfica muestra la cantidad de medicamentos que dieron origen a los millones de registros que se mostraron por año anteriormente:



Gráfica 3.2 Número de medicamentos distintos, consumidos por año. Fuente: Elaboración propia.

Como parte de la exploración de los datos y a fin de identificar tendencias, a continuación se muestra la gráfica que muestra la tendencia de consumo de los 10 medicamentos con mayor demanda a lo largo de los periodos analizados, expresada en número de piezas consumidas:




Gráfica 3.3 Los 10 medicamentos de mayor consumo global. Fuente: Elaboración propia.

En donde se observa que los medicamentos Paracetamol, Pantoprazol y Atorvastatina presentan los niveles de consumo más elevados, manteniéndose en promedio por encima de los 5 millones de piezas por periodo, lo que evidencia su alta rotación y relevancia dentro del instituto.

A lo largo del tiempo, las variaciones de consumo en estos tres medicamentos son moderadas y siguen un comportamiento relativamente estable, con ligeros picos en determinados periodos que podrían asociarse con incrementos estacionales en la demanda específicas, en el rango medio se ubican medicamentos como Cloruro de Potasio, Metformina y Losartán, los cuales muestran una tendencia más regular, sin cambios abruptos, lo que indica una demanda sostenida y predecible, ideal para planificar su reabastecimiento.

Finalmente, productos como Dieta Polimérica, Electrolitos, Metoprolol e Hidroclorotiazida presentan consumos más bajos, situándose entre 1 y 3 millones de piezas, aunque también mantienen una tendencia estable a lo largo del tiempo, en conjunto, el comportamiento de todas las series refleja una estabilidad general en la demanda, lo que sugiere que los patrones de consumo son consistentes y permiten la implementación de modelos predictivos confiables para la planeación de suministros y optimización de inventarios dentro del sistema de abastecimiento de medicamentos.

Ahora bien, a continuación se presenta la gráfica en donde se puede observar el comportamiento de consumo de los 10 medicamentos con menor demanda durante los periodos analizados, al igual mediante el número de piezas consumidas:



Gráfica 3.4 Top 10 de medicamentos con menor consumo global. Fuente: Elaboración propia.

Se observa que estos medicamentos presentan niveles de consumo considerablemente bajos y con una alta variabilidad, lo que refleja una demanda irregular y dependiente de necesidades clínicas específicas o tratamientos de baja frecuencia, entre los medicamentos mostrados, Lisinopril destaca por presentar picos atípicos de consumo que alcanzan hasta 1,200 piezas en ciertos periodos, posiblemente asociados a incrementos puntuales en la prescripción o a entregas concentradas.

En contraste, el resto de los medicamentos, como Idarubicina, Estradiol, Aripiprazol, Flutamida, Mesilato, Zuclopentil, Danazol y Clormadino, mantienen consumos bajos y relativamente estables, generalmente por debajo de las 400 piezas por periodo, lo que evidencia una rotación limitada y una demanda más esporádica, este comportamiento sugiere que estos productos forman parte de un grupo de medicamentos especializados o de uso restringido, cuya planificación de suministro debe basarse en la demanda histórica puntual y en el control estricto del inventario para evitar tanto desabastos como sobreabastecimiento.

Las tendencias observadas indican que el consumo de estos medicamentos es más sensible a fluctuaciones aleatorias y menos predecible en comparación con los medicamentos de alta demanda, lo que resalta la necesidad de aplicar modelos de predicción más robustos o personalizados para garantizar un abastecimiento eficiente y oportuno dentro del sistema instituto.

La estadística de consumos de piezas de medicamentos a nivel estado, se muestra a continuación:

Estado	Total de consumo en piezas
Ciudad de México	449,361,408
Estado de México	365,936,425
Jalisco	302,192,804
Nuevo León	207,488,206
Veracruz	191,130,605
Chihuahua	183,694,264
Sinaloa	175,896,928
Sonora	152,598,708
Guanajuato	147,201,280
Coahuila	137,310,959
Baja California Norte	130,477,117
Puebla	123,609,908
Michoacán	111,818,680
Tamaulipas	101,295,336
San Luis Potosí	92,600,317
Yucatán	73,971,401
Durango	73,849,062
Aguascalientes	66,736,761
Chiapas	65,245,124
Querétaro	61,460,665
Morelos	57,070,417
Hidalgo	54,585,230
Zacatecas	53,001,871
Oaxaca	52,618,531
Nayarit	52,114,923
Guerrero	51,841,367
Quintana Roo	41,504,311
Baja California Sur	34,071,994
Tabasco	30,539,699
Colima	30,211,803
Tlaxcala	23,599,099
Campeche	21,895,186

Tabla 3.2 Estadística de consumo en piezas de medicamentos por estado. Fuente: Elaboración propia.

La estadística representada en el mapa de calor siguiente, permite visualizar la distribución geográfica del consumo total de medicamentos a nivel estatal dentro del territorio nacional, en esta representación se identifican con claridad las zonas donde se concentra la mayor demanda, destacadas en tonos de azul más intenso, mientras que los estados con menor nivel de consumo se muestran en tonalidades más claras.

Este tipo de visualización facilita la interpretación espacial de los datos, permitiendo identificar patrones de comportamiento entre las diferentes regiones, los estados con mayor densidad poblacional y mayor infraestructura hospitalaria tienden a concentrar un volumen más elevado de consumos, lo que puede estar asociado con factores como el número de hospitales y unidades médicas, la disponibilidad de servicios de salud, la frecuencia de enfermedades y la capacidad de distribución.

Asimismo, el mapa de calor constituye una herramienta de apoyo para la toma de decisiones estratégicas en materia de planeación, abastecimiento, inversiones, etc., en donde se puede observar que los lugares de alta demanda podrían requerir mayores recursos o ajustes en la red de suministro, de esta forma, la representación geoespacial no solo evidencia las diferencias regionales en el consumo, sino que también se identifica una visión integral del comportamiento de la demanda a nivel nacional, siendo un elemento clave para el análisis y optimización de la gestión de medicamentos.






Diagrama 3.4 Mapa de calor de consumo por piezas de medicamentos por estado. Fuente: Elaboración propia

La gráfica siguiente muestra el comportamiento del top 10 de medicamentos con mayor demanda en el estado de Sonora, utilizada como ejemplo para ilustrar el análisis realizado por el modelo.

Estos datos representan la base inicial empleada para el desarrollo del modelo predictivo, considerando que el mismo procedimiento fue replicado de manera individual para cada una de las entidades federativas de la República, garantizando así un análisis consistente y comparable entre estados.



Gráfica 3.5 Top 10 de consumos de medicamentos en el estado de Sonora. Fuente: Elaboración propia.



Matriz 3.1 Matriz de correlación para el estado de Sonora. Fuente: Elaboración propia.

La matriz de correlación muestra la relación entre los patrones de consumo de medicamentos mes a mes, la cual permitió identificar cómo varían conjuntamente las variables en distintos periodos, utilizando el coeficiente de correlación que toma valores entre -1 y 1, los cuales son medidos mediante la siguiente escala:

Valores cercanos a 1 indican una alta correlación positiva, es decir, que el comportamiento de las variables es muy similar.

Valores cercanos a 0 indican poca o nula correlación, lo que sugiere que no hay una relación lineal clara entre esos periodos.

Valores negativos indicarían una correlación negativa, es decir, que un aumento en una variable se relaciona con una disminución en la otra.

En donde los resultados para el ejemplo del estado de Sonora, se tiene alta correlación, la mayoría de los valores se encuentran entre 0.8 y 1.0, lo que significa que el patrón de comportamiento entre meses consecutivos o cercanos en el tiempo es muy similar, esto puede deberse a factores como estacionalidad, continuidad en el tratamiento de enfermedades, o tendencias estables en el mercado farmacéutico.

En algunos casos se observa que los primeros meses de 2021 tienen correlaciones bajas con los meses más recientes, con valores que incluso bajan por debajo de 0.4, esto puede indicar un cambio en los patrones de consumo a lo largo del tiempo.

Por lo tanto, es un indicador positivo para llevar a cabo el desarrollo de los modelos de predicción ya que la mayoría de los estados presentan una correlación adecuada para el análisis.

3.11 Calidad de los datos

La calidad de los datos constituye un factor fundamental en el desarrollo de modelos de predicción basados en técnicas de aprendizaje automático, ya que de ella depende directamente la fiabilidad y precisión de los resultados obtenidos, en este sentido, se realizó una revisión exhaustiva del conjunto de datos empleados en el presente estudio con el propósito de verificar su integridad, consistencia y adecuación para el proceso de modelado.

Los datos recopilados son de naturaleza numérica, correspondientes a registros oficiales emitidos por la institución, lo cual garantiza su veracidad y trazabilidad, se constató que los valores no presentan decimales, lo que facilita su manejo y procesamiento dentro de los algoritmos de predicción, asimismo, durante la fase de exploración y depuración se comprobó que no existen registros nulos, vacíos ni duplicados, eliminando la necesidad de aplicar técnicas de imputación o estimación de valores faltantes.

De igual forma, los datos provienen de una fuente institucional oficial y certificada, lo que asegura que los registros reflejan de manera fidedigna los consumos reales y las operaciones del sistema de abasto y distribución de medicamentos, este aspecto es de suma relevancia, ya que el uso de información confiable y actualizada permite construir modelos predictivos más robustos, precisos y generalizables.

Por otro lado, se verificó la coherencia interna de las variables, asegurando que las relaciones entre los campos mantuvieran una lógica operativa acorde con los procesos administrativos y logísticos de la institución, no se detectaron incongruencias en las unidades de medida ni en los intervalos de tiempo, garantizando que el conjunto de datos cumple con los estándares de consistencia necesarios para el análisis.

En conclusión, el conjunto de datos utilizado presenta altos niveles de calidad, completitud y exactitud, condiciones que lo hacen idóneo para la implementación de modelos de predicción inteligentes, debido a ello, no fue necesario aplicar procesos adicionales de corrección, estimación o enriquecimiento de datos, lo que favorece un flujo de trabajo más eficiente y una mayor confiabilidad en los resultados del modelo.

3.12 Selección de los datos

La institución cuenta con diferentes grupos de insumos con los que abastece los diferentes hospitales y unidades médicas en toda la república mexicana, los cuales son:




Diagrama 3.5 Grupo de insumos. Fuente: Elaboración propia.

Sin embargo, para este trabajo el estudio se enfoca en el grupo de medicamentos, ya que son los que representan el mayor consumo a nivel nacional y tiene un mayor impacto en el servicio de los usuarios.

La siguiente gráfica presenta la distribución porcentual del consumo total de insumos dentro del Instituto, permitiendo identificar claramente cuáles categorías tienen mayor peso en la demanda global:




Diagrama 3.6 Distribución porcentual de consumo. Fuente: Elaboración propia

En ella se observa que los medicamentos constituyen el porcentaje predominante, con un 75.30% del consumo total, lo que confirma su papel central y estratégico dentro de las operaciones de abastecimiento institucional, este valor refleja que más de dos tercios de los insumos utilizados corresponden a esta categoría, por lo que su adecuada gestión resulta fundamental para evitar desabasto y asegurar la continuidad de los servicios.

Por otro lado, el material de curación representa un 24.31%, siendo la segunda categoría en importancia, aunque menor en proporción respecto a los medicamentos, su consumo sigue siendo significativo y necesario para el funcionamiento cotidiano de las áreas médicas, finalmente, las vacunas concentran únicamente el 0.39% del total, lo cual indica una baja participación relativa en comparación con los otros insumos, posiblemente debido a la periodicidad específica de su aplicación o a la existencia de programas con calendarios definidos.

Esta distribución evidencia que la mayor parte de los esfuerzos de pronóstico, planeación y optimización de la cadena de suministro debe concentrarse en los medicamentos, sin descuidar la importancia operativa de los demás grupos de insumos, la gráfica permite, por tanto, visualizar la estructura del consumo institucional y sirve como base para priorizar estrategias de gestión.

3.13 Limpieza de los datos

Como parte fundamental del proceso de preparación de datos para el desarrollo de modelos de predicción inteligentes, se llevó a cabo una etapa rigurosa de limpieza y depuración de la base de datos, este paso es esencial, ya que la calidad y consistencia de los datos inciden de manera directa en el desempeño y la precisión de los modelos predictivos.

Dentro del total de medicamentos registrados en la base de datos equivalente al 100% de insumos, se identificó que aproximadamente el 20% de ellos presentan una demanda baja, intermitente o completamente nula, este comportamiento se debe, en su mayoría, a que dichos medicamentos forman parte de programas de tratamientos especiales, los cuales están destinados a atender casos clínicos muy específicos, poco frecuentes o de carácter extraordinario, como resultado, el consumo de estos insumos es esporádico, y en varios períodos mensuales se reporta un consumo de cero unidades.

Incluir este tipo de medicamentos en los modelos de predicción representa un riesgo significativo para la precisión y estabilidad del sistema de pronóstico, ya que los valores nulos o cercanos a cero pueden afectar el entrenamiento de los algoritmos y la capacidad del modelo para generalizar patrones de comportamiento de la demanda, además, al tratarse de productos cuyo consumo no sigue una tendencia clara ni estacionalidades definidas, su comportamiento es inherentemente impredecible desde una perspectiva cuantitativa tradicional.

Por lo tanto, con el objetivo de mejorar la eficiencia del modelo, se decidió excluir este 20% de medicamentos con baja o nula demanda del conjunto de datos, esta decisión permite que el modelo se centre en aquellos productos que presentan un volumen de consumo representativo, constante y susceptible de ser modelado mediante técnicas de aprendizaje automático, optimizando así los resultados y evitando sesgos o distorsiones provocadas por datos atípicos.

Esta depuración inicial de los datos no solo contribuye a mejorar el rendimiento de los modelos inteligentes, sino que también responde a una necesidad práctica dentro del contexto institucional, al priorizar la predicción de productos cuya disponibilidad es crítica para el abastecimiento oportuno y la operación eficiente del sistema de salud.

3.14 Integración de los datos

Una vez realizada la limpieza y depuración de los datos, se procedió con la etapa de integración, la cual tuvo como objetivo consolidar toda la información necesaria para la construcción de los modelos de predicción de demanda, en este caso, no fue necesario generar nuevas tablas o estructuras de almacenamiento, ya que la información requerida se encontraba disponible dentro de los sistemas existentes de la Institución, no obstante, fue imprescindible realizar procesos de unión entre distintas tablas internas, con el fin de conformar una base de datos unificada, estructurada y adecuada para su procesamiento por parte de los algoritmos de aprendizaje automático.

Estas uniones se llevaron a cabo considerando claves comunes como identificadores de medicamentos, periodos de consumo y los destinos en donde se abastecen los insumos, el propósito fue vincular correctamente la información de consumo mensual con otras dimensiones críticas como el grupo terapéutico al que pertenece cada medicamento, la entidad federativa en la que se registró el consumo, y el año correspondiente, de esta forma, fue posible reconstruir el historial de consumo de medicamentos a nivel nacional, clasificado por grupo de medicamentos y distribuido temporalmente por año y mes.

A continuación, se presenta el diagrama de unión empleado para la consulta e integración de la información dentro del proceso de análisis de datos:




Diagrama 3.7 Diagrama de unión para consulta de información, Fuente: elaboración propia

3.15 Transformación de los datos

Una vez integrada la base de datos, se procedió con el formateo, con el objetivo de garantizar la correcta interpretación y procesamiento por parte de los modelos predictivos, este paso implicó la estandarización de los campos, la asignación de identificadores únicos y la transformación de ciertas variables clave para facilitar el análisis y la modelación.

En particular, cada uno de los estados de la República Mexicana, así como los distintos destinos de abastecimiento y los insumos, fueron codificados mediante identificadores numéricos, esta codificación no solo permitió un manejo más eficiente de los datos dentro de los algoritmos de aprendizaje automático, sino que también redujo la complejidad computacional al evitar el uso de variables categóricas de texto que requieren codificación adicional.

Adicionalmente, con el objetivo de implementar una estrategia de enfoque progresivo en el análisis, se procedió a ordenar los medicamentos de acuerdo con su volumen histórico de consumo, de mayor a menor, esta clasificación permitió aplicar el criterio previamente definido para la depuración de datos, descartando así el 20% de los insumos con baja o nula demanda, lo cual fue clave para mejorar la calidad de los datos y evitar sesgos en los modelos.

A partir de este ordenamiento, también se identificó el top 10 de medicamentos con mayor demanda a nivel nacional, lo que permitió establecer un punto de partida sólido para el análisis y desarrollo inicial de los modelos de predicción, esta selección se basó en el principio de Pareto, bajo la premisa de que un pequeño número de productos suele representar un alto porcentaje del consumo total, de esta forma, se inició el diseño, ajuste y validación de los modelos utilizando estos medicamentos como casos piloto, para posteriormente replicar la metodología con el resto de los insumos relevantes.

Este enfoque escalonado permitió validar la eficacia del modelo en un subconjunto altamente representativo antes de su implementación generalizada, optimizando así los tiempos de desarrollo y reduciendo riesgos asociados a la complejidad de modelar grandes volúmenes de datos desde el inicio.

3.16 Reducción de dimensiones

Con el objetivo de optimizar el procesamiento de los datos y mejorar la eficiencia y precisión de los modelos predictivos desarrollados, se implementó una estrategia de reducción de dimensiones, esta técnica, ampliamente utilizada en ciencia de datos, consiste en eliminar variables que no aportan valor significativo al modelo o que pueden aumentar la complejidad innecesaria, sin afectar sustancialmente la capacidad de predicción.

El primer paso dentro de esta estrategia fue enfocar el análisis únicamente en un grupo específico de medicamentos, descartando aquellos que pertenecen a otros grupos terapéuticos, priorizando los medicamentos y sobre todo los de mayor demanda y relevancia operativa para la institución, al reducir el universo de productos a un grupo más acotado y representativo, se logró concentrar los recursos computacionales y analíticos en aquellos insumos cuya predicción resulta más crítica para la toma de decisiones en materia de abastecimiento.

El segundo paso consistió en la depuración de variables que, si bien estaban presentes en la base de datos original, no aportan información útil para el objetivo de predicción de la demanda, entre las variables eliminadas del análisis se encuentran: los precios de los medicamentos, las unidades de presentación (por ejemplo, tabletas, frascos, ampolletas), el grupo de tratamientos al que pertenece cada insumo, y los distintos tipos de medidas utilizadas (miligramos, mililitros, gramos, etc.), estas variables, al no estar directamente relacionadas con el comportamiento de consumo en términos de volumen abastecido, fueron consideradas irrelevantes para el modelo en esta etapa.

Como resultado de este proceso de reducción de dimensiones, se definió un conjunto final de variables clave, las cuales sirvieron como base para el desarrollo del modelo de predicción, estas variables fueron: Medicamento (identificador del insumo específico), Destino de entrega (unidad médica, estado o entidad federativa correspondiente), Descripción del insumo (nombre o presentación estándar del medicamento), Consumo mensual en piezas abastecidas (variable objetivo del modelo).

Este conjunto reducido de variables permitió simplificar la estructura del modelo sin comprometer su capacidad para aprender patrones de consumo y generar predicciones precisas, además, facilitó la interpretación de los resultados por parte del equipo técnico y administrativo, promoviendo una mayor transparencia y utilidad práctica del sistema desarrollado.

3.17 Modelado

En esta etapa del proyecto, se procedió a la exploración y prueba de distintos modelos, con un enfoque específico en técnicas de aprendizaje automático y profundo, la elección de este enfoque metodológico se fundamentó en la naturaleza de los datos utilizados, todas las variables consideradas en el modelo son de tipo numérico continuo, y el objetivo principal consiste en predecir la demanda estimada en términos de número de piezas abastecidas para los distintos tipos de medicamentos y destinos de abastecimiento.

El aprendizaje profundo ha demostrado ser altamente efectivo en problemas de regresión donde existen múltiples variables independientes y relaciones no lineales complejas entre los datos, como es este caso, ya que los datos analizados tienen alta complejidad, por lo tanto, se buscó capturar patrones de comportamiento histórico de consumo a través del tiempo, considerando las particularidades de cada medicamento, su destino de entrega y el historial mensual de abastecimiento.

Durante esta fase, se evaluaron diversas arquitecturas de modelos, ajustando el número de capas ocultas, neuronas por capa, funciones de activación y métodos de regularización (normalización de los datos), con el fin de identificar la configuración adecuada para el problema específico, asimismo, se emplearon técnicas como la validación para evitar problemas de sobreajuste.

Considerando que la normalización de datos tiene que ver con la transformación de las variables de entrada a una escala común, esta práctica resulta esencial en los modelos de predicción, ya que evita que atributos con rangos numéricos más amplios dominen sobre aquellos de menor magnitud, además, facilita la estabilidad en los cálculos, mejora la velocidad de entrenamiento y permite que los algoritmos de optimización converjan de manera eficiente, por lo tanto, la normalización contribuye directamente a un mejor desempeño del modelo, reduciendo la varianza en los resultados y favoreciendo la capacidad de generalización.

Los modelos fueron entrenados utilizando algoritmos de optimización como Adam, así como funciones de pérdida basadas en el error cuadrático medio, apropiadas para tareas de regresión, el desempeño de cada modelo se evaluó a través de métricas estándar como el coeficiente de determinación, y el error absoluto medio, permitiendo comparar objetivamente la capacidad predictiva de cada alternativa.

La selección del modelo final se basó tanto en el desempeño cuantitativo como en la estabilidad de las predicciones a lo largo del tiempo, priorizando aquel que ofreciera un equilibrio entre precisión, capacidad de generalización y tiempo de entrenamiento razonable, este modelo fue posteriormente utilizado como base para replicar la predicción de demanda en otros medicamentos y entidades del país, asegurando consistencia en la metodología y escalabilidad en su aplicación.

3.18 Técnicas de modelado

Dentro del amplio espectro de técnicas disponibles para la modelación y predicción de la demanda, se llevó a cabo un proceso riguroso de selección y evaluación de modelos, con el objetivo de identificar aquellos que ofrecieran el mejor rendimiento en función de las características específicas de los datos institucionales y del problema a resolver, este proceso incluyó tanto modelos tradicionales de regresión como enfoques más avanzados basados en aprendizaje profundo, con especial énfasis en redes neuronales multicapa debido a su capacidad para capturar relaciones no lineales complejas.

La selección de los modelos se basó principalmente en la consideración de los siguientes aspectos: precisión de las predicciones, medida a través de métricas como el error cuadrático medio, el error absoluto medio y el coeficiente de determinación, capacidad de generalización, es decir, el desempeño del modelo al enfrentarse a datos no vistos durante el entrenamiento, interpretabilidad, que aunque es limitada en algunos modelos de aprendizaje profundo, se buscó compensar mediante la reducción de dimensiones y calidad en los datos, flexibilidad y potencial de mejora, considerando la posibilidad de ajustar hiperparámetros, incorporar nuevas variables o escalar el modelo a otros contextos.


Como estrategia de validación, los modelos fueron inicialmente desarrollados y probados sobre un conjunto representativo de estados de la República Mexicana, seleccionados con base en tres criterios principales: la disponibilidad y calidad de los datos históricos, la relevancia del volumen de demanda en dichos estados, y la diversidad de patrones de consumo observados, lo que permitió asegurar que el modelo fuera capaz de adaptarse a distintos escenarios.

Durante esta fase de pruebas iniciales, se evaluó el comportamiento de los modelos en entornos con diferentes volúmenes de consumo, variaciones estacionales y particularidades regionales, esto permitió realizar ajustes en las arquitecturas, identificando así las mejores para su implementación.

Posteriormente, y una vez alcanzado un desempeño satisfactorio en los estados piloto, los modelos fueron replicados y adaptados para el resto de las entidades federativas del país, la decisión de elaborar un modelo independiente por estado se debe principalmente a que cada entidad presenta características particulares: los tipos de medicamentos utilizados varían entre destinos, algunos incluso no se repiten en otras regiones, los volúmenes de consumo muestran diferencias significativas, y factores como la cantidad de usuarios y la densidad geográfica influyen de manera directa en el comportamiento de la demanda y, por ende, en el desempeño del modelo.

Debido a estas variaciones estructurales, se optó por desarrollar un modelo específico para cada estado, aplicando ajustes adicionales cuando las condiciones locales así lo requerían, con esta estrategia escalable, fue posible extender el alcance del sistema de predicción de manera eficiente, manteniendo la coherencia metodológica y asegurando una aplicación robusta y adecuada a nivel nacional.

A continuación se presenta el promedio de los resultados obtenidos a partir del coeficiente de determinación de algunos modelos desarrollados durante el proceso de evaluación con diversas técnicas de modelado para la predicción, aplicadas a cada una de las entidades federativas de la República, los resultados permiten observar que los modelos construidos mediante técnicas de regresión son los que presentan el mejor desempeño, al mostrar una mayor capacidad explicativa en la estimación de la demanda de medicamentos:



Gráfica 3.6 Resultados promedio de coeficiente de determinación en técnicas de modelos de predicción. Fuente: Elaboración propia.

3.19 Modelo

El modelo que mostró el mejor rendimiento durante la fase de experimentación, pruebas y validación fue desarrollado bajo un enfoque de regresión, el cual se consolidó como la opción adecuada para el análisis y predicción de la demanda institucional de medicamentos, este tipo de modelo destacó por su estabilidad, simplicidad estructural, interpretabilidad y capacidad para capturar comportamientos cuantitativos consistentes en series históricas de consumo, incluso dentro de un entorno caracterizado por datos extensos y con patrones variables en el tiempo.

A diferencia de otros enfoques inicialmente evaluados, el modelo de regresión demostró ser altamente eficiente para identificar relaciones entre los valores históricos y las fluctuaciones mensuales de consumo, su naturaleza permite ajustar de manera precisa la relación entre las variables predictoras y la variable objetivo, lo cual es especialmente relevante en el contexto institucional, donde es necesario anticipar la demanda con altos niveles de confiabilidad para evitar desabastos y eficiente la cadena de suministro.

Uno de los aspectos relevantes, es que la regresión permitió capturar tendencias lineales y no lineales dependiendo del tipo de regresor implementado, ofreciendo una solución flexible y adaptable a las particularidades de cada clave de medicamento y destino de entrega, esto es fundamental dado que algunos insumos presentan comportamientos estacionales, mientras que otros siguen patrones de crecimiento gradual, decrecimiento sostenido o fluctuaciones atípicas derivadas de situaciones extraordinarias o variaciones en la demanda institucional.

A pesar de que ciertos medicamentos exhiben comportamientos irregulares o discontinuos, el modelo de regresión logró ajustarse adecuadamente mediante procesos de normalización, ajuste de parámetros y validación cruzada, permitiendo detectar tanto ciclos de consumo como tendencias de largo plazo, esta capacidad analítica representó una ventaja significativa frente a modelos más complejos que dependen estrictamente de secuencias temporales, y que en varios casos presentaron problemas de sobreajuste o sensibilidad excesiva a valores extremos.

Los resultados obtenidos durante la fase de validación reflejaron un desempeño superior frente a otros enfoques evaluados, evidenciando niveles de precisión favorables y predicciones estables en el tiempo, esto permitió consolidar la regresión como el modelo más confiable y adecuado para este proyecto, al ofrecer un equilibrio óptimo entre precisión, interpretabilidad y eficiencia computacional.

El modelo de regresión representa una solución sólida y técnicamente viable para la predicción de la demanda de medicamentos dentro de la Institución, su incorporación en los procesos de planeación de la demanda permitirá fortalecer la gestión del abastecimiento, mejorar la toma de decisiones operativas y estratégicas, y garantizar una respuesta oportuna ante las necesidades de los usuarios, contribuyendo al uso eficiente de los recursos y a la continuidad del servicio médico.

El modelo de predicción de demanda cuenta con 1 capa de entrada, 6 capas ocultas y 1 de salida, a continuación se muestra la arquitectura empleada para la predicción de demanda para un destino específico, se observa una red neuronal profunda compuesta por una capa de entrada, seis capas ocultas densamente conectadas y una capa de salida, organizada de forma secuencial para procesar la información histórica y generar una estimación final.

La capa de entrada, ubicada en el extremo izquierdo y representada por nodos de color azul, integra las variables utilizadas como insumo para el modelo, en este caso, cada nodo corresponde a un mes de consumo histórico de cada medicamento, conformando una ventana temporal que captura la evolución de la demanda a lo largo del tiempo, esto permite que el modelo identifique patrones estacionales, tendencias y fluctuaciones relevantes para la predicción.

En el centro de la figura se encuentran las capas ocultas, ilustradas mediante nodos verdes, estas capas están formadas por neuronas totalmente conectadas, lo que significa que cada neurona recibe información de todas las neuronas de la capa anterior, su función principal es aprender las relaciones no lineales presentes en los datos mediante la aplicación de funciones de activación no lineales, en este caso ReLU, que facilita la propagación del gradiente y acelera el proceso de entrenamiento.

La distribución de neuronas por cada capa oculta permite realizar una transformación progresiva de la información, extrayendo características complejas que mejoran la capacidad predictiva del modelo, finalmente, en el extremo derecho se encuentra la capa de salida, identificada con color rojo, cuya función es generar el valor pronosticado correspondiente al consumo esperado de los medicamentos utilizados en el destino de entrega ejemplificado, esta capa utiliza una activación lineal, adecuada para modelos de regresión donde se requiere producir valores numéricos continuos, el número de salidas puede variar ya que depende de la cantidad de medicamentos que utilice cada estado.

Las líneas que conectan cada neurona representan las sinapsis o pesos del modelo, ajustados durante el entrenamiento mediante el algoritmo de retropropagación del error y el optimizador Adam, estos pesos determinan la influencia que cada variable de entrada ejerce sobre la predicción final, y se calibran iterativamente para minimizar la función de pérdida basada en el error cuadrático medio.

En conjunto, esta arquitectura profunda permite capturar patrones complejos y dinámicos en los datos históricos de consumo de medicamentos en el Instituto, logrando generar predicciones estables y precisas, lo que resulta fundamental para mejorar la planeación y gestión del suministro de medicamentos dentro de la institución.




Diagrama 3.8 Arquitectura del modelo de predicción. Fuente: Elaboración propia.

Para el desarrollo y entrenamiento del modelo de predicción inteligente basado en la arquitectura de regresión, fue necesario definir cuidadosamente los parámetros y componentes clave que intervienen en su rendimiento, la correcta selección de estos elementos resulta fundamental para garantizar la estabilidad del modelo, optimizar su capacidad de generalización y asegurar un aprendizaje eficiente a partir de los datos históricos de consumo, a continuación, se describen los principales aspectos técnicos considerados durante la etapa de configuración y entrenamiento del modelo:

Optimizador: El tipo de optimizador utilizado fue Adam, debido a su eficiencia computacional y buen desempeño en problemas complejos, especialmente en redes neuronales profundas.

Función de activación: Se empleó la función ReLU en las capas ocultas, ya que permite una activación no lineal eficiente, acelera el entrenamiento y ayuda a evitar el problema del desvanecimiento del gradiente.

Función de pérdida: Se utilizó el error cuadrático medio, apropiado para tareas de regresión y eficaz en la predicción de valores continuos, ya que penaliza fuertemente los errores grandes y proporciona un aprendizaje más preciso en este tipo de problemas.

Épocas: Algunos modelos fueron entrenados con 79 épocas y otros con 90 épocas, permitiendo observar el rendimiento del modelo a lo largo del tiempo y ajustarlo según el comportamiento del error de entrenamiento y validación.

Entrenamiento: Los datos fueron escalados y normalizados, lo cual es un paso fundamental para mejorar el rendimiento y la estabilidad del entrenamiento, lo cual garantiza que todas las características tengan la misma escala, evitando que algunas dominen sobre otras y facilitando la convergencia del modelo.

Sobre entrenamiento: Para prevenir el sobreentrenamiento, se empleó la técnica de EarlyStopping, la cual detiene automáticamente el entrenamiento cuando la métrica de validación (por ejemplo, la pérdida) deja de mejorar durante un número determinado de épocas, esta técnica no solo evita que el modelo se ajuste demasiado a los datos de entrenamiento, sino que también reduce significativamente el tiempo de entrenamiento. Resulta especialmente adecuada para el modelo de predicción de medicamentos desarrollado, ya que el número óptimo de épocas varía entre los distintos estados de la República, permitiendo una adaptación eficiente durante el entrenamiento.

3.20 Ajuste de los parámetros

Durante el proceso de entrenamiento del modelo, uno de los principales parámetros ajustados fue el número de épocas utilizadas para cada estado, este parámetro determina cuántas veces el modelo recorre completamente el conjunto de datos de entrenamiento, y su ajuste es importante para alcanzar un buen desempeño sin incurrir en sobreajuste.

En este estudio, se observó que algunos estados requieren diferentes cantidades de épocas para lograr una convergencia óptima, mientras que algunos alcanzaban su mejor rendimiento con 79 épocas, otros requerían hasta 90 épocas para mejorar la precisión, a continuación, se presenta una tabla que resume el número de épocas utilizadas por cada estado:

Estado	Épocas
Aguascalientes	79
Baja California Norte	79
Baja California Sur	79
Campeche	79
Chiapas	79
Chihuahua	79
Ciudad de México	79
Coahuila	79
Colima	79
Durango	79
Estado de México	90
Guanajuato	90
Guerrero	79
Hidalgo	90
Jalisco	90
Michoacán	79
Morelos	90
Nayarit	90
Nuevo León	79
Oaxaca	90
Puebla	79
Querétaro	79
Quintana Roo	79
San Luis Potosí	79
Sinaloa	79
Sonora	90
Tabasco	79
Tamaulipas	79
Tlaxcala	79
Veracruz	90
Yucatán	79
Zacatecas	90

Tabla 3.3 Número de épocas por estado. Fuente: Elaboración propia.

Esto se debe a que cada estado presenta patrones temporales, niveles de variabilidad y estructuras internas de datos distintas, lo que influye directamente en la velocidad con la que el modelo logra aprender relaciones relevantes durante el entrenamiento, en estados donde las series muestran comportamientos más estables o tendencias más definidas, el modelo alcanza la convergencia óptima con un menor número de épocas, como es el caso de aquellos que requirieron únicamente 79 épocas, debido a que la función de pérdida disminuye rápidamente y deja de aportar mejoras significativas después de cierto punto.

Por el contrario, los estados que necesitaron 90 épocas suelen presentar mayor complejidad en sus datos, ya sea por variaciones estacionales más marcadas, fluctuaciones abruptas, o una mayor dispersión en las observaciones, esta mayor complejidad obliga al modelo a realizar un mayor número de iteraciones para ajustar adecuadamente sus parámetros y capturar la dinámica subyacente sin caer en sobreajuste.

Estas diferencias justifican la necesidad de emplear un número de épocas específico para cada estado, garantizando así que el entrenamiento sea suficientemente profundo para capturar los patrones relevantes, pero no excesivo al punto de deteriorar la capacidad de generalización del modelo.

3.21 Validación

Los modelos fueron evaluados utilizando las métricas de error cuadrático medio, error absoluto medio y el Coeficiente de Determinación, con el objetivo de validar el rendimiento de cada modelo por estado, estas métricas permiten cuantificar la precisión de las predicciones realizadas por los modelos en comparación con los valores reales, en donde se tienen los siguientes resultados:

Estado	Error cuadrático medio	Error absoluto medio	Coeficiente de determinación
Aguascalientes	0.02	0.05	0.98
Baja California Norte	0.01	0.04	0.99
Baja California Sur	0.01	0.03	0.97
Campeche	0.03	0.04	0.97
Chiapas	0.17	0.07	0.87
Chihuahua	0.09	0.06	0.91
Ciudad de México	0.48	0.09	0.80
Coahuila	0.43	0.07	0.84
Colima	0.52	0.11	0.83
Durango	0.12	0.08	0.92
Estado de México	0.03	0.03	0.97
Guanajuato	0.10	0.09	0.86
Guerrero	0.05	0.05	0.95
Hidalgo	0.28	0.15	0.88
Jalisco	0.09	0.05	0.91
Michoacán	0.03	0.05	0.85
Morelos	0.30	0.09	0.82
Nayarit	0.03	0.05	0.96
Nuevo León	0.11	0.08	0.99
Oaxaca	0.11	0.07	0.92
Puebla	0.02	0.03	0.94
Querétaro	0.05	0.04	0.96
Quintana Roo	0.39	0.10	0.97
San Luis Potosí	0.06	0.06	0.97
Sinaloa	0.01	0.03	0.99
Sonora	0.55	0.18	0.87
Tabasco	0.01	0.03	0.96
Tamaulipas	0.19	0.09	0.93
Tlaxcala	0.02	0.06	0.92
Veracruz	0.04	0.05	0.96
Yucatán	0.02	0.10	0.96
Zacatecas	0.28	0.31	0.96

Tabla 3.4 Resultados de métricas de evaluación. Fuente: Elaboración propia

Los resultados obtenidos mediante las métricas permiten evaluar el rendimiento del modelo predictivo en cada estado de manera individual, en general, los valores muestran un buen desempeño en la mayoría de los estados, especialmente considerando que en muchos casos el coeficiente de determinación supera el 0.90, lo que indica una alta capacidad del modelo para explicar la variabilidad de los datos observados.

Los resultados de las métricas fueron clasificados en dos intervalos para su evaluación mediante el Coeficiente de Determinación, esta clasificación permite identificar el nivel de precisión y la capacidad predictiva del modelo, facilitando así la interpretación de su desempeño, los modelos ubicados en el intervalo de alto desempeño presentan una excelente capacidad para explicar la variabilidad de los datos y generan predicciones altamente confiables, por otro lado, los modelos que se encuentran en el rango de medio desempeño muestran un ajuste aceptable; si bien capturan una proporción significativa de la variabilidad, aún existe margen de mejora para incrementar su precisión.

La tabla siguiente resume los criterios utilizados:

Intervalos	Evaluación
Coeficiente de Determinación > 0.90	Alto desempeño
$0.80 \leq \text{Coeficiente de Determinación} \leq 0.90$	Medio desempeño

Tabla 3.5 Intervalos de desempeño para resultados. Fuente: Elaboración propia.

Por lo tanto, los modelos que presentaron un alto desempeño demostraron una notable capacidad predictiva, alcanzando valores de coeficiente de determinación superiores a 0.90, lo que refleja una fuerte correlación entre los valores estimados por el modelo y los consumos reales observados, estos resultados evidencian la efectividad del enfoque basado en regresión, el cual fue capaz de capturar patrones temporales complejos y relaciones no lineales presentes en los datos históricos de consumo de medicamentos.

El alto rendimiento alcanzado en estos estados sugiere que los modelos se beneficiaron de bases de datos con mayor estabilidad y consistencia en los registros, así como de comportamientos de demanda más regulares y predecibles, esto permitió que el modelo se ajustara con mayor precisión las variaciones en el tiempo, logrando una menor tasa de error y una mejor capacidad de generalización, a continuación, se presentan los resultados obtenidos en los estados con mejor desempeño:

Estado	Coeficiente de determinación
Baja California Norte	0.99
Nuevo León	0.99
Sinaloa	0.99
Aguascalientes	0.98
Baja California Sur	0.97
Campeche	0.97
Estado de México	0.97
Quintana Roo	0.97
San Luis Potosí	0.97
Nayarit	0.96
Querétaro	0.96
Tabasco	0.96
Veracruz	0.96
Yucatán	0.96
Zacatecas	0.96
Guerrero	0.95
Puebla	0.94
Tamaulipas	0.93
Durango	0.92
Oaxaca	0.92
Tlaxcala	0.92
Chihuahua	0.91
Jalisco	0.91

Tabla 3.6 Modelos con alto rendimiento. Fuente: Elaboración propia.


Durante la fase de evaluación del desempeño de los modelos desarrollados, se observó que, si bien la mayoría alcanzó niveles de precisión superiores al 90%, existieron algunos casos en los que el rendimiento fue moderado, estos resultados reflejan las diferencias en la calidad y estabilidad de los datos de consumo registrados por cada estado, así como la influencia de factores externos como variaciones en la demanda, disponibilidad de inventarios, tiempos de entrega o condiciones logísticas que pueden afectar el comportamiento histórico de los medicamentos.

En este sentido, los modelos que presentaron un desempeño medio, con valores del coeficiente de determinación comprendidos entre 0.80 y 0.88, se describen a continuación, es importante destacar que, si bien estos modelos logran capturar una proporción considerable de la variabilidad de los datos, aún muestran áreas susceptibles de optimización, por ello, el análisis correspondiente a estos estados puede ser refinado mediante ajustes en los parámetros del modelo, la selección de variables o la incorporación de técnicas avanzadas de procesamiento de datos, con el propósito de mejorar su rendimiento y alcanzar niveles más altos de precisión predictiva:

Estado	Coeficiente de determinación
Hidalgo	0.88
Chiapas	0.87
Sonora	0.87
Guanajuato	0.86
Michoacán	0.85
Coahuila	0.84
Colima	0.83
Morelos	0.82
Ciudad de México	0.80

Tabla 3.7 Modelos con medio rendimiento. Fuente: Elaboración propia.

El gráfico que se presenta a continuación permite observar el rendimiento de cada modelo, ordenado de mayor a menor, según el estado analizado:



Gráfica 3.7 Rendimiento de los modelos, según el Coeficiente de Determinación. Fuente: Elaboración propia.


El gráfico anterior muestra el rendimiento de los modelos, evaluado mediante el coeficiente de determinación, para cada una de las entidades federativas consideradas en el análisis, los resultados se presentan de manera ordenada, de mayor a menor desempeño, lo que permite identificar con claridad las diferencias en la capacidad predictiva de los modelos según el estado analizado.

Se observa que los modelos correspondientes a Baja California Norte, Nuevo León, Sinaloa, Aguascalientes y Baja California Sur alcanzan los valores más altos, cercanos a 1.0, lo cual indica un ajuste prácticamente perfecto entre las predicciones y los valores observados, en contraste, los modelos de Morelos y Ciudad de México presentan los valores más bajos de, cercanos a 0.80, aunque todavía dentro de un rango aceptable que evidencia un buen desempeño general.


3.22 Rendimiento del modelo

A continuación, se presentan las gráficas que muestran el rendimiento de cada uno de los modelos en los distintos estados analizados en donde se comparan los valores reales contra los valores de la predicción, en general, los modelos exhiben un desempeño aceptable, ya que existe una alta coincidencia entre los valores estimados y la demanda real de medicamentos en la mayoría de los puntos, asimismo, se observa que los modelos son capaces de identificar tanto los valores extremos de demanda como los periodos de baja demanda, lo que prueba su capacidad para predecir con alta precisión.


Esta relación cercana entre valores reales y predichos evidencia que el modelo no solo es capaz de anticipar la demanda promedio, sino que también identifica de forma razonablemente precisa los cambios abruptos, los incrementos súbitos y los periodos de baja demanda, por lo tanto, estos resultados respaldan la eficiencia del modelo y muestran que su capacidad predictiva es suficientemente sólida para ser utilizada como herramienta de apoyo en la planeación de la demanda de medicamentos, contribuyendo así a mejorar la toma de decisiones operativas.




Gráfica 3.8 Rendimiento del modelo para el estado de Aguascalientes. Fuente: Elaboración propia.




Gráfica 3.9 Rendimiento del modelo para el estado de Baja California Sur. Fuente: Elaboración propia.




Gráfica 3.10 Rendimiento del modelo para el estado de Baja California Norte. Fuente: Elaboración propia




Gráfica 3.11 Rendimiento del modelo para el estado de Campeche. Fuente: Elaboración propia.




Gráfica 3.12 Rendimiento del modelo para el estado de Chiapas. Fuente: Elaboración propia




Gráfica 3.13 Rendimiento del modelo para el estado de Chihuahua. Fuente: Elaboración propia




Gráfica 3.14 Rendimiento del modelo para el estado de Ciudad de México. Fuente: Elaboración propia




Gráfica 3.15 Rendimiento del modelo para el estado de Coahuila. Fuente: Elaboración propia




Gráfica 3.16 Rendimiento del modelo para el estado de Colima. Fuente: Elaboración propia




Gráfica 3.17 Rendimiento del modelo para el estado de Durango. Fuente: Elaboración propia




Gráfica 3.18 Rendimiento del modelo para el Estado de México. Fuente: Elaboración propia




Gráfica 3.19 Rendimiento del modelo para el estado de Guanajuato. Fuente: Elaboración propia




Gráfica 3.20 Rendimiento del modelo para el estado de Guerrero. Fuente: Elaboración propia




Gráfica 3.21 Rendimiento del modelo para el estado de Hidalgo. Fuente: Elaboración propia




Gráfica 3.22 Rendimiento del modelo para el estado de Jalisco. Fuente: Elaboración propia




Gráfica 3.23 Rendimiento del modelo para el estado de Michoacán. Fuente: Elaboración propia




Gráfica 3.24 Rendimiento del modelo para el estado de Morelos. Fuente: Elaboración propia




Gráfica 3.25 Rendimiento del modelo para el estado de Nayarit. Fuente: Elaboración propia




Gráfica 3.26 Rendimiento del modelo para el estado de Nuevo León. Fuente: Elaboración propia




Gráfica 3.27 Rendimiento del modelo para el estado de Oaxaca. Fuente: Elaboración propia




Gráfica 3.28 Rendimiento del modelo para el estado de Puebla. Fuente: Elaboración propia




Gráfica 3.29 Rendimiento del modelo para el estado de Querétaro. Fuente: Elaboración propia




Gráfica 3.30 Rendimiento del modelo para el estado de Quintana Roo. Fuente: Elaboración propia




Gráfica 3.31 Rendimiento del modelo para el estado de San Luis Potosí. Fuente: Elaboración propia




Gráfica 3.32 Rendimiento del modelo para el estado de Sinaloa. Fuente: Elaboración propia




Gráfica 3.33 Rendimiento del modelo para el estado de Sonora. Fuente: Elaboración propia




Gráfica 3.34 Rendimiento del modelo para el estado de Tabasco. Fuente: Elaboración propia




Gráfica 3.35 Rendimiento del modelo para el estado de Tamaulipas. Fuente: Elaboración propia




Gráfica 3.36 Rendimiento del modelo para el estado de Tlaxcala. Fuente: Elaboración propia



Gráfica 3.37 Rendimiento del modelo para el estado de Veracruz. Fuente: Elaboración propia



Gráfica 3.38 Rendimiento del modelo para el estado de Yucatán. Fuente: Elaboración propia



Gráfica 3.39 Rendimiento del modelo para el estado de Zacatecas. Fuente: Elaboración propia

3.23 Determinación de los próximos pasos

Una vez desarrollado el modelo de predicción de la demanda de medicamentos y comprobado que su rendimiento supera el estándar de aprobación establecido por la institución, el siguiente paso consiste en llevar a cabo una prueba piloto, esta fase tiene como propósito evaluar el funcionamiento del modelo en un entorno operativo, aplicándolo inicialmente en los diez estados de la república que registraron el mayor desempeño durante la etapa de entrenamiento:

Estado	R ²
Baja California Norte	0.99
Nuevo León	0.99
Sinaloa	0.99
Aguascalientes	0.98
Baja California Sur	0.97
Campeche	0.97
Estado de México	0.97
Quintana Roo	0.97
San Luis Potosí	0.97
Nayarit	0.96
Querétaro	0.96

Tabla 3.8 Estados piloto para la etapa de prueba del modelo. Fuente: Elaboración propia

El periodo de la prueba piloto se establece en seis meses, ya que dicho lapso constituye el mínimo requerido por la institución para la evaluación de proyectos estratégicos, este intervalo de tiempo permitirá observar con suficiente amplitud el comportamiento del modelo, validar su eficiencia en distintos escenarios de consumo y medir su capacidad de respuesta frente a variaciones estacionales o contingencias en la demanda.

Posterior a esta etapa y en función de los resultados obtenidos, se plantea replicar gradualmente la operación del modelo en el resto de los estados de la república, mediante un esquema de implementación escalonada, este enfoque progresivo busca garantizar que, antes de la adopción total, el sistema se ajuste a las particularidades de cada entidad, reduciendo riesgos y mejorando la precisión predictiva.

Adicionalmente, como parte de la consolidación del proyecto, se propone el desarrollo de una interfaz interactiva que facilite la consulta, manipulación y explotación de los resultados de manera oportuna, flexible y automatizada, esta herramienta estará dirigida a los usuarios designados para la planeación de insumos, quienes podrán generar pronósticos actualizados de medicamentos, interactuar con periodos de tiempo de proyección, dashboards interactivos, visualizar indicadores clave para el seguimiento y monitoreo de resultados, y exportar reportes personalizados sobre la demanda de medicamentos en cada estado, de esta forma, se asegura no solo la operatividad del modelo, sino también su integración efectiva dentro de los procesos institucionales.

A continuación se muestra la propuesta del nuevo diagrama de flujo de la estimación de la demanda y abastecimiento de medicamentos que se puede ejecutar en la interfaz propuesta a desarrollar:




Diagrama 3.9 Diagrama de flujo del nuevo modelo de abasto. Fuente: Elaboración propia

De igual forma, se contempla la capacitación del personal responsable de operar la interfaz destinada a la estimación de la demanda, con el propósito de garantizar un manejo adecuado y un entendimiento integral de la herramienta, este proceso formativo se complementa con el desarrollo de manuales de usuario y de operación que sirvan como guía de consulta, así como con la definición de planes de mantenimiento preventivo y correctivo necesarios para asegurar la continuidad, confiabilidad y sostenibilidad del sistema a lo largo del tiempo.

Como parte final, es importante señalar que este proyecto fue desarrollado específicamente para el grupo de insumos correspondiente a los medicamentos, sin embargo, dado que el Instituto cuenta con diversos grupos adicionales de insumos, se plantea como perspectiva futura la replicación y adaptación de este mismo desarrollo para el resto de los insumos, con el fin de ampliar su alcance y generar un impacto integral en los procesos de planeación y gestión de la cadena de suministro institucional.

3.24 Implementar el modelo

Una vez concluido el desarrollo del modelo predictivo y habiendo obtenido resultados que superan los estándares de precisión establecidos por el Instituto, se procede a la fase de despliegue, la cual incluye diversas actividades, en primer lugar, se lleva a cabo la validación de las pruebas piloto, las cuales permiten comprobar en escenarios controlados el rendimiento y la confiabilidad del modelo en comparación con los métodos utilizados previamente, esto garantiza que el sistema cumple con los objetivos planteados y se encuentra en condiciones de ser implementado en un entorno real de operación.

Posteriormente, con base en los resultados alcanzados, se desarrolla una interfaz interactiva diseñada de manera ad hoc para atender las necesidades específicas del área de Planeación y de la Cadena de Suministro, dicha interfaz tiene como propósito facilitar el uso del modelo por parte de los usuarios finales, permitiendo la consulta oportuna de predicciones, la manipulación de escenarios de análisis y la generación de reportes personalizados que apoyen la toma de decisiones estratégicas.

La liberación de la tecnología se efectúa de manera coordinada con el área de Planeación de Tecnología, a fin de asegurar el cumplimiento de las normas institucionales, políticas de seguridad informática y lineamientos regulatorios que rigen en la organización, esto permite que se realice de manera ordenada, minimizando riesgos operativos y preservando la integridad de la infraestructura tecnológica existente.

Finalmente, con la infraestructura habilitada y las validaciones correspondientes, se dispone de la capacidad para ejecutar los movimientos, instalaciones y procesos necesarios que permitirán bajar a los usuarios finales el proyecto global, esto implica no solo la implementación técnica del modelo, sino también la capacitación al personal, la creación de manuales de operación y la definición de un plan de soporte y mantenimiento, de esta forma, el despliegue no se limita a la entrega de una solución tecnológica, sino que asegura la apropiación del sistema por parte de las áreas usuarias, garantizando la sostenibilidad del proyecto y la posibilidad de su expansión futura hacia otros niveles de operación institucional.

3.25 Monitoreo y rendimiento

El proceso de monitoreo se propone llevar a cabo a través de un conjunto de indicadores clave de desempeño (KPIs) diseñados para evaluar de manera continua y sistemática el comportamiento del modelo frente a la operación real, entre los principales indicadores a considerar se encuentran: la comparación de los resultados proyectados contra los consumos reales de medicamentos por estado, el nivel de abastecimiento en los almacenes regionales y centrales, el grado de surtimiento oportuno de recetas a los usuarios finales, los niveles de cumplimiento y confiabilidad por parte de los proveedores, los tiempos promedio de entrega de los insumos, así como la generación de alertas relacionadas con índices máximos y mínimos de inventario.

Todos estos indicadores estarán disponibles para consulta mediante la interfaz operativa diseñada específicamente para los usuarios responsables de la planeación, complementada con tableros de control interactivos (dashboards) que permitirán visualizar en tiempo real la información más relevante, dichos tableros no solo facilitarán la interpretación de los datos, sino que también ofrecerán la posibilidad de generar reportes personalizados, realizar comparaciones históricas y detectar tendencias que puedan anticipar escenarios críticos.

De esta manera, el monitoreo no se limita únicamente a la verificación del desempeño del modelo predictivo, sino que se convierte en una herramienta integral para la gestión estratégica de la cadena de suministro, al brindar información clara, precisa y actualizada, se fortalece la capacidad institucional para tomar decisiones oportunas, optimizar procesos y garantizar que el suministro de medicamentos se realice de forma eficiente y en tiempo y forma.

4 CAPÍTULO IV

4.1 Resultados

En este capítulo se presentan los resultados obtenidos a partir del desarrollo e implementación del modelo predictivo propuesto para estimar la demanda de medicamentos, el proceso se llevó a cabo de manera estructurada, desde la obtención de los datos históricos hasta la evaluación del rendimiento de los modelos entrenados, con el fin de comparar los resultados del sistema inteligente frente al método tradicional utilizado por la institución.

La primera etapa consistió en la recolección de los registros históricos de consumo de medicamentos correspondientes al periodo comprendido entre los años 2020 y 2025, clasificados por estado de la República Mexicana y por clave de medicamento, el conjunto de datos consolidado sirvió como base para la construcción de los modelos predictivos.

Durante la fase de preparación de datos se realizó una limpieza de la base, eliminando columnas innecesarias y atributos redundantes que no aportan valor al modelo, asimismo, se verificó la ausencia de valores nulos o vacíos, confirmando la consistencia y completitud del conjunto de datos, los registros se encuentran expresados en valores numéricos enteros, lo que facilitó el procesamiento y análisis posterior, evitando la necesidad de realizar transformaciones adicionales o estimaciones de valores faltantes.

Con base en esta validación, se concluye que los datos son de alta calidad, lo cual garantiza la confiabilidad de los resultados obtenidos en las etapas siguientes.

Para la construcción de los modelos predictivos se realizaron diversas pruebas empleando diferentes técnicas de aprendizaje automático, después de comparar el desempeño de cada modelo en función de métricas estadísticas de error y ajuste, la arquitectura basada en regresión fue la que mostró el mejor comportamiento en la mayoría de los casos.


Los modelos fueron entrenados de manera independiente para cada estado de la república, a fin de capturar los patrones particulares de consumo de medicamentos según la dinámica poblacional y los indicadores de salud regionales, los resultados muestran un coeficiente de determinación que oscila entre 0.80 y 0.99, lo que evidencia un excelente nivel de ajuste entre los valores predichos y los valores reales observados, estos resultados indican que los modelos fueron entrenados de manera adecuada, logrando una eficiente predicción de la demanda futura.

A continuación, se presenta un gráfico de dispersión que ejemplifica los resultados obtenidos durante la fase de entrenamiento del modelo para uno de los estados analizados, en este diagrama se comparan los valores reales de consumo con las predicciones generadas por el modelo de regresión, la línea punteada roja representa la línea de referencia ideal, aquella en la que cada punto coincidiría exactamente con el valor real, indicando una predicción perfecta.

Al observar la distribución de los puntos, se aprecia que la mayoría de las predicciones se concentran cerca de la línea de referencia, especialmente en los rangos bajos y medios de demanda, esto sugiere que el modelo es capaz de capturar adecuadamente las tendencias generales del consumo y generar estimaciones consistentes en la mayor parte del comportamiento histórico, el patrón de alineación confirma que existe una relación proporcional y coherente entre las predicciones y los valores observados, lo cual evidencia una buena capacidad del modelo para aprender la estructura subyacente de los datos.

Sin embargo, también es posible identificar algunos puntos alejados de la línea ideal, particularmente en los niveles de demanda más elevados, estos casos pueden obedecer a variaciones abruptas, picos atípicos o comportamientos no lineales difíciles de anticipar, dichas discrepancias resultan comunes en escenarios de alta variabilidad como el consumo de medicamentos, donde factores externos pueden influir de manera significativa.

En términos generales, el gráfico muestra un desempeño sólido del modelo, destacando su capacidad para aproximarse a los valores reales en la mayoría de las observaciones, este comportamiento contribuye a validar su utilidad para la estimación de la demanda, proporcionando una herramienta confiable para apoyar los procesos de planeación, gestión de inventarios y toma de decisiones dentro del ámbito institucional.



Gráfica 4.1 Gráfico de dispersión de rendimiento para un estado. Fuente: Elaboración propia

Actualmente, la institución emplea un método de promedio simple para la estimación de la demanda de medicamentos, considerando principalmente los últimos 12 periodos históricos y en algunos casos 6 meses, este procedimiento presenta un nivel de precisión promedio por debajo del 75%, lo que se traduce en desviaciones importantes entre las proyecciones y el consumo real.

En contraste, el modelo inteligente desarrollado mediante la técnica de regresión supera significativamente este indicador, al presentar niveles de exactitud superiores al 90% en la mayoría de los casos evaluados, esto representa una mejora sustancial en la calidad de las estimaciones, lo que contribuye directamente a una mejor planeación del abastecimiento, reducción de desabasto, optimización de inventarios y mayor eficiencia en la distribución de medicamentos.

4.2 Conclusiones

El pronóstico dentro de una organización representa un elemento fundamental y constituye el punto de partida para la ejecución de las actividades relacionadas con la cadena de suministro, los resultados obtenidos en la estimación de la demanda influyen de manera directa en el cumplimiento de los objetivos de cada área de la empresa y, por ende, en el nivel de servicio ofrecido al cliente.

En este caso, el proyecto se enfocó en la industria farmacéutica, específicamente en una institución responsable de brindar servicios de salud y seguridad social a más de 70 millones de personas, esta magnitud de atención incrementa la necesidad de contar con un modelo de predicción altamente eficiente, ya que su desempeño puede impactar de manera directa en la salud y el bienestar de los usuarios.

Por tal motivo, el análisis se llevó a cabo en el área de abastecimiento, basándose en la metodología CRISP-DM, con el propósito de estructurar de manera ordenada las etapas del proceso analítico, actualmente, la institución emplea una metodología de pronóstico sustentada en el promedio simple, cuyos resultados son posteriormente comunicados a las distintas áreas que intervienen en la gestión de la cadena de suministro, sin embargo, al evaluar dichos pronósticos, se identificó que presentan un nivel de eficiencia inferior al 75%, al compararse las estimaciones con el consumo real de medicamentos.

Esta baja precisión ha generado una serie de problemáticas operativas que afectan directamente el desempeño institucional, tales como baja rotación de inventarios, pérdidas por caducidades, incremento en los riesgos de robo, sobreabastecimiento, y costos elevados asociados al almacenamiento y mantenimiento de existencias, además, el impacto más relevante se refleja en el nivel de servicio al usuario, el cual no alcanza los objetivos establecidos por la institución, comprometiendo así la disponibilidad oportuna de medicamentos y la calidad del servicio de salud brindado a la población.

Por ello, surge la necesidad de desarrollar un modelo de predicción inteligente, aprovechando la información generada diariamente por el Instituto sobre los consumos de demanda en cada estado del país, este enfoque busca capitalizar el valor de los datos históricos disponibles, reconociendo que el aprendizaje automático constituye una herramienta con un alto potencial para el manejo y análisis de grandes volúmenes de información, permitiendo así obtener pronósticos más precisos y eficientes que fortalezcan la toma de decisiones en el proceso de abastecimiento.

Inicialmente, el estudio se centró en el grupo de medicamentos, dado que la organización cuenta con diversos grupos de insumos destinados a la atención médica, sin embargo, el grupo de medicamentos representa el 75.3% del consumo total a nivel nacional, motivo por el cual se seleccionó como el foco principal del proyecto.

Una vez obtenidos los datos a través del ERP institucional, se realizó un proceso de limpieza y depuración de información, eliminando aquellas columnas que no aportan valor al análisis, durante esta etapa, se identificó que aproximadamente el 20% de los medicamentos presentan un comportamiento de consumo con alta variabilidad en sus tendencias, por lo que dicho porcentaje fue excluido del modelo predictivo con el fin de garantizar una mayor precisión y estabilidad en los resultados.

Una vez obtenida la base de datos, se procedió a realizar pruebas con diferentes técnicas de modelado predictivo con el propósito de desarrollar modelos de predicción inteligentes, cada modelo fue evaluado con base en su rendimiento y capacidad de ajuste a los datos históricos, como resultado de este proceso, se determinó que la técnica basada en regresión presentó un desempeño superior en comparación con las demás metodologías analizadas, mostrando una mayor precisión en la estimación de la demanda.

Posteriormente, esta técnica fue empleada para desarrollar un modelo individual para cada estado, obteniendo como resultado un rendimiento mínimo del 80% y máximo del 99%, de acuerdo con la evaluación basada en el coeficiente de determinación, estos valores indican que los modelos fueron entrenados exitosamente y superan significativamente el desempeño del modelo actualmente utilizado por la organización para el cálculo de los pronósticos de demanda.

Los resultados obtenidos evidencian que el uso de algoritmos avanzados de aprendizaje profundo permite identificar patrones complejos de comportamiento en la demanda de medicamentos del Instituto, dichos patrones, al ser abordados mediante métodos estadísticos tradicionales, presentan un menor nivel de precisión y capacidad de adaptación frente a las variaciones reales del consumo.

El desempeño de los modelos de regresión valida la viabilidad de incorporar herramientas de aprendizaje automático en los procesos de planeación institucional, favoreciendo la toma de decisiones estratégicas basadas en datos reales y proyecciones confiables, esto además incrementará los niveles de abastecimiento, reducirá las pérdidas financieras y principalmente se cumplirá con el objetivo de potenciar el servicio de atención a los usuarios.

En términos operativos, la implementación del modelo propuesto contribuiría significativamente a mejorar la eficiencia logística dentro de la organización, al permitir una planificación precisa de los recursos y una optimización en la gestión de inventarios, esto se traduciría en una reducción de costos asociados tanto al sobreabastecimiento como al desabastecimiento de medicamentos, además de fortalecer la capacidad de respuesta ante las variaciones en la demanda por parte de las diferentes unidades médicas y hospitales del país, asimismo, el uso de un modelo predictivo más robusto permitiría anticipar comportamientos estacionales y tendencias emergentes, facilitando la toma de decisiones estratégicas en el proceso de suministro y distribución.

Finalmente, se propone el desarrollo de una interfaz interactiva, flexible y de fácil uso, diseñada específicamente para el personal del área de abastecimiento, esta herramienta permitiría ejecutar los modelos de predicción de manera periódica y automatizada, generando reportes actualizados y visualizaciones que apoyen la interpretación de resultados, además, se contempla la implementación de un programa de inducción y capacitación dirigido al personal involucrado, con el fin de garantizar una correcta adopción de la herramienta y promover una cultura organizacional orientada al uso de la analítica de datos como soporte para la toma de decisiones.

4.3 Referencias

- Albarrán, D. R. (2022). Un modelo para predecir la demanda en farmacias. *Red Marka*, 15.
- Andrés, D. (2 de febrero de 2023). *Machine Learning Pills*. Obtenido de Variables exógenas en modelos ARIMA: <https://mlpills.dev/series-temporales/variables-exogenas-en-modelos-arima/>
- Arana, C. (2021). Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales. *Econstor*, 26.
- Arengas Acosta, J. M., Guzmán Cabrera, R., & López Ramírez, M. (2024). Impacto del preprocesamiento en la clasificación automática de textos usando aprendizaje supervisado y reuters. *Revista Colombiana de Tecnologías de Avanzada*, 9.
- Ayala Castrejón, R. F. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. *Revista mexicana de economía y finanzas*, 24.
- Banda, H. O. (2022). Cadena de suministro para pequeñas y medianas empresas de servicios industriales: Desarrollo y aplicación de modelo de gestión. *Revista Venezolana de Gerencia*, 16.
- Burgh Day, C., & Leeuwenburg, T. (2023). Machine learning for numerical weather and climate modelling. *Geoscientific Model Development*, 45.
- Erick Lambis-Alandete, M. J.-G.-H. (2023). Comparación de algoritmos de deep learning para pronósticos en los precios de criptomonedas. *Redalyc*, 5.
- Espinosa Zuñiga, J. J. (2020). Aplicación de metodología CRISP-DM para segmentación geográfica de una base de datos pública. *Ingeniería, investigación y tecnología*, 12.
- Espinosa, J. J. (2020). Aplicación de metodología CRISP-DM para segmentación geográfica de una base de datos pública. *Scielo*, 14.
- Fabian, M. L. (mayo de 2022). Diseño de investigación para la propuesta de un modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos en Guatemala. Guatemala.
- Fernández, C. J. (2020). Metodología para pronosticar demanda y clasificar inventarios en empresas comercializadoras de productos mayoristas. *Scielo*.
- García, M. d. (2022). Predictors of the price of white corn in Jalisco and Michoacán. *Revista Mexicana Ciencias Agrícolas*, 12.
- Google. (2025). *Google Colab*. Obtenido de <https://colab.research.google.com/?hl=es>
- Hernández, B. L. (2022). Gestión del conocimiento y sostenibilidad en la gestión de la cadena de suministro. *Dialnet*, 17.
- Herrera Ardila, J. C., & Roncancio Peña, J. C. (2022). Prototipo para la detección de rostros utilizando el lenguaje de programación Python. *Tecnología, Investigación y Academia*, 200-220.
- Herrera Cofre, D. F. (22 de septiembre de 2020). Predicción para el mercado de acciones con redes neuronales LSTM. Bogotá, Colombia.
- IBM. (17 de 8 de 2021). *Mexico-IBM*. Obtenido de <https://www.ibm.com/docs/es/spss-modeler/saas?topic=guide-business-understanding>
- Inzunza, J. J. (abril de 2020). *Segmentación de mercado*. Obtenido de <http://biblioteca.udgvirtual.udg.mx/jspui/handle/123456789/3432>

- Jaramillo Duque, Á. (2022). Pronóstico de la Radiación Solar para la Generación de Energía Eléctrica Fotovoltaica. Medellín, Antioquia, Colombia.
- Jesús García, J. M. (2020). *Ciencia de Datos, Técnicas analíticas y aprendizaje estadístico*. Bogotá: Altaria, SL.
- Kuma, V. R. (2023). Forecasting Drug Demand for Optimal Medical. *International Journal of Innovative Science and Research Technology*, 9.
- Mira Segura, L., Martínez Cruz, M., Trejo Martínez, A., Kryvko, A., & Dorantes Benavidez, H. (2024). Optimización de inventarios en la industria del plástico: un caso de éxito con el método Holt-Winters. *Amazonia investiga*, 11.
- Moncayo, J. R.-A. (2021). Desarrollo de un sistema inteligente para predecir los consumos de medicamentos genéricos de mayor demanda en el distrito de salud 06D05 Guano-Penipe, aplicando técnicas de regresión de machine learning. Riobamba, Ecuador.
- Moreno Pallares, M. G., Moreno Pallares, R. R., & Mejia Peñafiel, E. F. (2022). Entrenamiento de Redes Neuronales Artificiales con Aprendizaje No Supervisado en el control de calidad del análisis. *Polo del Conocimiento*, 10.
- Muñoz Cañón, N. D., & Romero Triana, J. A. (2021). Optimización de los hiperparámetros de una máquina de regresión de soporte vectorial utilizando enjambre de partículas para el pronóstico de casos de COVID-19. *Investigación e innovación en Ingenierías*, 21.
- Navarro, D. L. (2020). Ciencia de datos y estudios globales: aportaciones y desafíos metodológicos. *OpenEdition Journals*, 23.
- Oracle. (11 de marzo de 2024). Oracle. Obtenido de <https://www.oracle.com/mx/big-data/what-is-big-data/>
- Ramírez, J. D. (2021). Aprendizaje Automático y Aprendizaje Profundo. *Scielo*, 2.
- Ramos, D. I. (2022). Propuesta de control de inventarios en una empresa de alimentos. *Publicaciones e investigación, especializada en Ingeniería*, 8.
- Rouhiainen, L. (2020). *Inteligencia artificial, 101 cosas que debes saber hoy sobre nuestro futuro*. Madrid: Alienta.
- Salgado, H. (2022). Errores de medición.
- Sánchez Trujillo, M. G. (2021). Metodología CRISP-DM en la gestión de proyecto de Data Mining. Caso enfermedades dermatológicas. *International Conference on Project Management*, 13.
- Santos, O. O. (2023). De cadena de suministros a cadena de valor: devenir y pertinencia de los conceptos. *Scielo*, 11.
- Saucedo, C. A.-V.-C. (2022). Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características. *Scielo*.
- Siddiqui, R., Azmat, M., Ahmed, S., & Kummerd, S. (2021). A hybrid demand forecasting model for greater forecasting accuracy: the case of the pharmaceutical industry. *Sage Journals Home*, 11.
- Sosa, C. J.-Y.-D. (2020). Metodología para pronosticar demanda y clasificar inventarios en empresas comercializadoras de productos mayoristas. *Scielo*.
- Suárez, Y. S. (2021). Retos actuales de la logística y la cadena de suministro. *Scielo*, 7.
- Sujatha, K. (2022). A Machine Learning Approach to Predict Drug Stock Based on Consumption. *International Journal of Early Childhood Special Education*, 11.

- Tito Aco, A. E., Hanco Condori, B. O., & Pérez Vera, Y. (2023). Análisis comparativo de Técnicas de Machine Learning para la predicción de casos de deserción universitaria. *Revista Ibérica de Sistemas y Tecnologías de Información*, 84-98.
- Trillo, E. T. (2023). *Impacto de la Inteligencia Artificial en*. Madrid: Escuela Técnica Superior de.
- Vanegas, L. L. (2020). La economía de la salud en México. *Cepal*, 14.
- Venegas, R. (2021). Aplicaciones de inteligencia artificial para la clasificación automatizada de propósitos comunicativos en informes de ingeniería. *Revista Signos*, 29.
- Víctor Pedrero, K. R.-G.-A.-P. (2021). Generalidades del Machine Learning y su aplicación en la gestión sanitaria en Servicios de Urgencia. *Scielo*, 6.
- Villegas, J. C. (2023). Aplicación web de minería de datos para pronosticar la demanda de medicamentos en la farmacia de un establecimiento de salud. Chiclayo, Perú.
- Zúñiga, J. J. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Scielo*, 10.