

**UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO**  
**FACULTAD DE INGENIERÍA**  
**ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN**



**APLICACIÓN WEB DE MINERÍA DE DATOS PARA PRONOSTICAR  
LA DEMANDA DE MEDICAMENTOS EN LA FARMACIA DE UN  
ESTABLECIMIENTO DE SALUD**

**TESIS PARA OPTAR EL TÍTULO DE  
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

**AUTOR**

**JOSE CARLOS VILCHEZ VILLEGAS**

**ASESOR**

**RICARDO DAVID IMAN ESPINOZA**

**<https://orcid.org/0000-0003-0409-8773>**

**Chiclayo, 2023**

**APLICACIÓN WEB DE MINERÍA DE DATOS PARA  
PRONOSTICAR LA DEMANDA DE MEDICAMENTOS EN LA  
FARMACIA DE UN ESTABLECIMIENTO DE SALUD**

PRESENTADA POR  
**JOSE CARLOS VILCHEZ VILLEGAS**

A la Facultad de Ingeniería de la  
Universidad Católica Santo Toribio de Mogrovejo  
para optar el título de

**INGENIERO DE SISTEMAS Y COMPUTACIÓN**

APROBADA POR

Oscar Alex Serquén Yparraguirre  
PRESIDENTE

Roger Ernesto Alarcón García  
SECRETARIO

Ricardo David Iman Espinoza  
VOCAL

## **Dedicatoria**

A Dios que me ha guiado siempre y me ha dado la fortaleza necesaria para no rendirme y alcanzar mis metas.

A mis padres, hermanas, hermano, sobrino y a toda mi familia que me acompañó y me dio ánimos para continuar.

## **Agradecimientos**

A mi asesor de tesis, Mgtr. Ricardo David Iman Espinoza, por su dedicación, paciencia y orientación para el desarrollo de este trabajo de investigación.

A mi universidad, docentes, familia y amigos, por el apoyo académico y emocional que me brindaron durante toda la carrera.

A la empresa donde se ejecutó esta tesis, por las facilidades brindadas y la oportunidad de aplicar mis conocimientos.

# Aplicación web de minería de datos para pronosticar la demanda de medicamentos en la farmacia de un establecimiento de salud

## INFORME DE ORIGINALIDAD

8%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

1%

PUBLICACIONES

%

TRABAJOS DEL ESTUDIANTE

## FUENTES PRIMARIAS

1

[creativecommons.org](https://creativecommons.org)

Fuente de Internet

1%

2

[tesis.usat.edu.pe](https://tesis.usat.edu.pe)

Fuente de Internet

1%

3

[hdl.handle.net](https://hdl.handle.net)

Fuente de Internet

1%

4

[docplayer.es](https://docplayer.es)

Fuente de Internet

<1%

5

[epdf.pub](https://epdf.pub)

Fuente de Internet

<1%

6

[conaiisi.unsl.edu.ar](https://conaiisi.unsl.edu.ar)

Fuente de Internet

<1%

7

[www.coursehero.com](https://www.coursehero.com)

Fuente de Internet

<1%

8

[qdoc.tips](https://qdoc.tips)

Fuente de Internet

<1%

## Índice

Resumen .....	8
Abstract .....	9
I. Introducción .....	10
II. Marco teórico .....	14
Antecedentes .....	14
Bases teóricas .....	20
III. Metodología .....	26
IV. Resultados .....	27
V. Discusión.....	35
VI. Conclusiones .....	39
VII. Recomendaciones.....	40
VIII. Referencias.....	41
IX. Anexos.....	45

## Lista de tablas

Tabla 1. Escala para R-Cuadrado .....	24
Tabla 2. Escala para MAPE .....	24
Tabla 3. Métodos de investigación.....	26
Tabla 4. Técnicas e instrumentos de recolección de datos.....	26
Tabla 5. Resumen de los resultados del primer objetivo.....	29
Tabla 6. Resumen de los resultados del segundo objetivo.....	32
Tabla 7. Escala cualitativa para ítems del rendimiento .....	33
Tabla 8. Valores para las variables "m" y "p" .....	34
Tabla 9. Escala para la evaluación del rendimiento .....	34
Tabla 10. Resumen de los resultados del tercer objetivo .....	35

## Lista de figuras

Figura 1. Arquitectura de la solución .....	27
Figura 2. Función calcular el valor R-Cuadrado del modelo .....	28
Figura 3. Función para evaluar R-Cuadrado en todos los modelos .....	28
Figura 4. Resultados del primer objetivo .....	29
Figura 5. Histograma de los resultados del primer objetivo .....	29
Figura 6. Función para calcular el valor MAPE del modelo.....	31
Figura 7. Función para evaluar MAPE en todos los modelos.....	31
Figura 8. Resultados de la evaluación del segundo objetivo.....	31
Figura 9. Histograma de los resultados del segundo objetivo.....	32
Figura 10. Histograma de los resultados del tercer objetivo .....	34

## Resumen

Esta investigación surgió con el objetivo de implementar una solución de minería de datos para pronosticar la demanda de medicamentos a partir de grandes volúmenes de datos y con un alto nivel de precisión en la farmacia de un establecimiento de salud debido a que durante el análisis de la situación inicial se detectaron oportunidades de mejora en el proceso de planeamiento del abastecimiento que podrían permitir maximizar la demanda atendida y minimizar los costos de mantener medicamentos por mucho tiempo en el almacén. Para cumplir con lo planificado se utilizó la metodología CRISP-DM y las redes neuronales, logrando construir un modelo de pronóstico por cada medicamento existente. Tras los procesos de entrenamiento y mejora, los modelos obtuvieron en promedio un valor de 0.9 para la métrica R-cuadrado, demostrando un buen nivel de adaptación al comportamiento de la demanda, y un valor promedio de 17.88% durante la medición del MAPE con lo que garantizaron un alto nivel de precisión. Por otro lado, se construyó una aplicación web que permite a los usuarios obtener reportes de los pronósticos y actualizar los parámetros de los modelos, así como reentrenarlos o crear nuevos. Finalmente, las interfaces de esta aplicación obtuvieron en promedio 92 puntos tras su evaluación en base a los criterios propuestos por una herramienta de medición de rendimiento.

**Palabras clave:** Redes neuronales, pronóstico de demanda, aplicación web.



## Abstract

This research was designed with the objective of implement a data mining solution to forecast the demand for medicines from big data volumes and with a high level of accuracy in the pharmacy of a health center because during the analysis of the initial situation, opportunities for improvement in the supply planning process were detected that could maximize the satisfied demand and minimize the costs of keeping medicines for a long time in the warehouse. To comply with the plan, the CRISP-DM methodology and neural networks were used to build a forecast model for each existing drug. After the training and improvement processes, the models obtained an average value of 0.9 for the R2 metric, demonstrating a good level of adaptation to demand behavior, and an average value of 17.88% during the MAPE measuring, guaranteeing a high level of accuracy. On the other hand, a web application was built to allow users to obtain forecast reports and update model parameters, as well as retrain them or create new ones. Finally, the interfaces of this application scored an average of 92 points after evaluation based on the criteria proposed by a performance measurement tool.

**Keywords:** Neural networks, demand forecasting, web application.

## I. Introducción

Desde finales de los ochenta, la economía y la sociedad han cambiado radicalmente debido a la revolución digital y el uso masificado del internet, asimismo, durante los últimos años se ha evidenciado un crecimiento exponencial y uso globalizado de las tecnologías digitales originados por la búsqueda de democratizar el acceso a la información. Este crecimiento acelerado del uso de tecnologías ha hecho que muchas empresas incluyan en su día a día la utilización de dispositivos y aplicaciones que se apoyan en la computación en la nube, inteligencia artificial, cadena de bloques y otras ciencias como la analítica de datos, que precisamente ha cobrado especial importancia en la simplificación del proceso de toma de decisiones [1].

El sector salud no ha sido ajeno a los cambios mencionados y ello ha generado un aumento de la cantidad de información digital que almacenan, por lo mismo, se ha visto en la necesidad de utilizar herramientas capaces de analizar grandes volúmenes de datos para ayudar a agilizar diversas tareas tales como la detección temprana de enfermedades, la identificación de factores de riesgo o la planeación del abastecimiento de medicamentos, siendo esta última una tarea clave según la Organización Mundial de la Salud (OMS) que define el desabastecimiento de medicamentos como un problema de suma importancia que afecta a todo el mundo [2], tal es la situación que la Asamblea Mundial de la Salud solicitó, en el informe de secretaría del 2017 [3], que la directora general exhortara a los estados miembros a reconocer esta problemática y desarrollar políticas farmacéuticas eficientes.

En un estudio de MC-Kinsey [4], se afirma que si Estados Unidos utilizara en el sector salud las tecnologías de Big Data de la forma correcta podría generar 300 billones de dólares, de los cuales dos tercios serían producto de la reducción del 8% del gasto en salud. Además, en dicho estudio también se hace mención del informe donde International Business Machines Corporation (IBM) destaca que el sistema de salud de Estados Unidos es ineficiente y ha malgastado 2.5 trillones de dólares, situación que podría mejorar hasta en un 35% si se compara con otros sectores industriales donde sí se utilizan las tecnologías de Big Data.

A pesar de ser una problemática de importancia reconocida y habiendo tenido tiempo suficiente para tomar las medidas necesarias, durante el año 2018, en España, un estudio [5] reveló que hubo 1143 desabastecimientos de medicamentos, situación que afectó directamente a 990 especialidades y sus pacientes, asimismo, la mediana de días de desabastecimiento fue de 79.

En el Perú, el sector público es el comprador del 70% de medicamentos [6] y tiene un sistema deficiente de gestión y logística que origina un desabastecimiento crónico que a su vez ocasiona que el 79.5% de pacientes no reciba sus medicamentos a tiempo y termine comprándolos por su cuenta, sólo por poner un ejemplo, en el Hospital Daniel Alcides Carrión existió un desabastecimiento de 45 medicamentos y otros 73 se encontraban con sub stock, pero además, habían 150 medicamentos con sobre stock y sólo 84 de todos los medicamentos con los que contaba dicho hospital estaban en un nivel óptimo de abastecimiento [7]. Dicha situación ha ido empeorando puesto que la primera ola del COVID 19 ha ocasionado el desabastecimiento de los medicamentos genéricos.

La problemática descrita no es ajena al sector privado, la organización donde se aplicó esta investigación manifestó que a pesar de contar con un plan de abastecimiento solían existir rupturas de stock que impedían brindar una atención completa a sus pacientes. Esta situación generaba costos adicionales por el hecho de necesitar nuevas órdenes de compra para los periodos que ya se consideraban abastecidos, adicionalmente, algunos medicamentos no se agotaban en el tiempo previsto, pero gracias a la política de inventario que manejan se ha podido evitar siempre su caducidad, declararon también que en el sistema que usaban, todos los medicamentos estaban listados, pero no podían visualizar indicadores porcentuales del consumo total por años o meses. Por último, resaltaron la dificultad que les representaba el proceso de pronóstico de la demanda ya que no tenían un sistema capaz de analizar la cantidad de información con la que contaban [8].

Así, la ausencia de un sistema de análisis de demandas potenciales y el hecho de determinar las cantidades a comprar de cada medicamento sin contemplar la totalidad de la información disponible han contribuido al sobre stock y sub stock en la farmacia del establecimiento de salud donde se aplicó esta investigación. Ante esto se formuló el siguiente problema: ¿Cómo pronosticar la demanda de medicamentos a partir de grandes volúmenes de datos y con un alto nivel de precisión en la farmacia de un establecimiento de salud?

Al respecto existen investigaciones que afrontaron un problema similar, por ejemplo, Leclerc [9] buscó desarrollar un modelo de pronóstico de la demanda de medicamentos por periodos mensuales para una empresa farmacéutica, para ello utilizó la metodología Cross Industry Standard Process for Data Mining (CRISP-DM) y probó varios modelos partiendo desde los más sencillos como Promedio móvil simple hasta modelos más complejos como Autoregressive integrated moving average (ARIMA), obteniendo finalmente que el mejor modelo logró un 78% de certeza en sus pronósticos. Del mismo modo Molina [10] recopiló información con respecto a los indicadores de gestión de las ventas y stock y con ayuda de la

metodología Knowledge Discovery in Databases (KDD) empleó el modelo Autoregressive integrated moving average with exogenous variables (ARIMAX) junto a redes neuronales y el modelo Holt-Winters para generar pronósticos de la demanda, obteniendo al final una precisión del 90% en los pronósticos que generó.

Partiendo de las investigaciones mencionadas, la minería de datos se mostró como una solución viable que permitió realizar el análisis de grandes cantidades de datos para encontrar patrones de comportamiento de la demanda que sean útiles en la toma de decisiones, además, también estuvo involucrada la estadística con sus técnicas de muestreo y visualización de datos junto con la depuración y el cálculo de indicadores, así mismo, la inteligencia artificial destacó contribuyendo con algoritmos de procesamiento de los datos de tipo heurístico, basados en el modelo de razonamiento humano. En tal sentido, se definió como objetivo general para esta investigación: Implementar una solución de minería de datos para pronosticar la demanda de medicamentos a partir de grandes volúmenes de datos y con un alto nivel de precisión en la farmacia de un establecimiento de salud. Y se plantearon como objetivos específicos: Alcanzar un valor mayor a 0.6 en el nivel de adaptación del modelo de pronóstico a la demanda de medicamentos en la farmacia de un establecimiento de salud. Lograr un porcentaje menor a 40% en el error de precisión del pronóstico de la demanda de medicamentos en la farmacia de un establecimiento de salud. Y obtener una puntuación mayor o igual al 90% en la evaluación del rendimiento de la aplicación web utilizando una herramienta de medición de rendimiento.

Esta investigación tuvo como propósito descubrir patrones de comportamiento que generen conocimiento útil para la empresa en particular y para el área de salud en general. Se justificó científicamente en que la utilización de los avances en arquitecturas de redes neuronales contribuiría al conocimiento existente sobre el pronóstico de demandas y ello representaría una oportunidad de “mejora” según la clasificación de la matriz de innovación propuesta por Gregor y Hevner [11]. Económicamente se justificó en que el desarrollo de una solución haciendo uso de herramientas y software gratuito mantendría los costos de adopción muy bajos y que, sumado a ello, la información que generaría el sistema permitiría detectar situaciones específicas que no son percibidas fácilmente para en base a ellas proponer medidas que optimicen los recursos relacionados con el proceso de abastecimiento de medicamentos. Para el aspecto social, la justificación fue que la mejora en el proceso de abastecimiento permitiría mantener en todo momento los niveles apropiados de stock de medicamentos y los beneficiarios de ello serían los pacientes que los tendrían disponibles en el momento que sean necesarios. Tecnológicamente estuvo justificada en que el uso de

aplicaciones web, arquitecturas distribuidas e inteligencia artificial se corresponde con la dirección actual del desarrollo tecnológico siendo que la combinación antes mencionada permitiría acceder a la información desde cualquier lugar sólo con un dispositivo que tenga acceso a internet y de forma independiente al sistema operativo e incluso sin la necesidad de que cuente con una alta capacidad de procesamiento. Finalmente, la investigación fue del tipo “aplicada”, que según Jose Lozada [12], este tipo de investigación busca generar conocimiento y aplicarlo a la brevedad sobre problemas prácticos, en cuanto a la contrastación de a hipótesis, esta entraría dentro de la clasificación cuasi experimental debido a que sólo se contará con un grupo de control [13].

## II. Marco teórico

Para la ejecución de esta investigación fue necesario identificar antecedentes relacionados con la problemática que se pretendía abordar, de esta manera se tendría una recopilación de los hallazgos más relevantes, adicionalmente fue necesario también el análisis de las bases teórico científicas que engloben los temas vinculados al problema, a la solución propuesta y al sector donde se ejecutará.

### *Antecedentes*

Los antecedentes han sido seleccionados por guardar una fuerte relación o semejanza con la presente investigación, algunos de ellos están enfocados en el sector salud y tratan la demanda de medicamentos, sin embargo, algunos otros estudian el comportamiento de la demanda de productos ajenos a este sector.

### *Antecedentes internacionales*

Leclerc [9] presenta en su investigación la problemática de una empresa farmacéutica para determinar los productos que deberían estar disponibles en un determinado momento para poder satisfacer la demanda, en base a ello planteó el uso de la metodología CRISP-DM para desarrollar modelos estadísticos que reduzcan los sesgos existentes en el proceso de planificación del abastecimiento, logrando analizar 117 series de tiempo utilizando 10 modelos considerados como los mejores para la tarea en cuestión, entre estos modelos se encontraron el promedio móvil simple, promedio móvil doble, suavización exponencial simple, suavización exponencial doble, Holt Winters y ARIMA, cabe resaltar que estos modelos fueron implementados usando los paquetes “fpp2” y “forecast” de R. Con ello se estimó que la precisión de los pronósticos pasó de un promedio de 62% a 78% en líneas generales. Además, el autor concluye que a pesar de las mejoras es posible que los modelos deban modificarse con el tiempo para que se adapten a las variaciones propias de la naturaleza cambiante del mercado farmacéutico. Por otra parte, propone que se mejore el trabajo incluyendo datos más precisos de la demanda real, ya que el trabajo fue realizado con datos de ventas sin considerar casos en los que no haya habido stock para concretar las solicitudes de compra. Esta tesis fue tomada en consideración como antecedente debido a que analiza el uso de un modelo independiente por cada medicamento para abstraer el comportamiento real de la demanda, también porque analizó los modelos agrupándolos en no estacionales sin tendencia,

no estacionales con tendencia, autorregresivos integrados de media móvil y modelos estacionales, siendo que los datos que obtuvo con ello nos aportarán una visión general del funcionamiento de los modelos y de la facilidad o dificultad de analizar un determinado tipo de serie temporal.

Molina [10] narra que en un laboratorio farmacéutico tenían problemas de baja rotación de ciertos productos y sub stock de otros lo que generaba problemas económicos al laboratorio, afirma que, durante el año 2018, la falta de stock ocasionó que se dejara de atender el 11% de las órdenes de compra. Para solucionar esta situación, construyó un modelo analítico basado en minería de datos que permita predecir las ventas del laboratorio farmacéutico. En cuanto a la metodología de investigación, menciona que utilizó Design Science Research (DSC), mientras que para implementar la solución utilizó la metodología Knowledge Discovery in Databases (KDD) y con ello evaluó modelos ARIMAX, redes neuronales y Holt Winters haciendo uso del programa RapidMiner. El modelo final obtuvo una precisión del 90%, esto resultó conveniente en comparación con la precisión que se manejaba anteriormente en sus proyecciones que era en promedio del 85%, sin embargo, es importante resaltar que el modelo final mostró que dentro de cada subcategoría de productos el comportamiento era distinto por lo cual el uso de un solo modelo para todas las subcategorías no resultaría totalmente adecuado. El aporte de esta tesis está en que entre los modelos utilizados para generar los pronósticos de la demanda se encontraron redes neuronales y ello implica que los resultados obtenidos sirven como punto de partida para el diseño de futuros modelos al mismo tiempo que el proceso de evaluación podría ser replicado para catalogar como adecuado o no este tipo de soluciones o de otra forma deducir las características de la situación que harían posible obtener buenos resultados al utilizar redes neuronales.

En una investigación de Buissonneau, Mosquera y Gómez [14] se trata la problemática de una empresa pastelera donde existieron pérdidas económicas ocasionadas por el deficiente manejo del stock que se daba en el área de producción, en la empresa se tenían desabastecimientos en fechas de alta demanda y acumulación de materia prima en fechas de baja demanda, en tal sentido se propuso determinar el modelo apropiado para pronosticar la demanda y evitar que esta situación se siga repitiendo, entre los modelos que se pusieron a prueba se encontraron el promedio móvil, promedio móvil ponderado y suavizado exponencial simple, logrando determinar que para los dos productos estudiados, el promedio móvil ponderado fue la técnica que tuvo el menor error porcentual absoluto medio, siendo este del 22,3% y 20% respectivamente. Por último, los autores concluyeron que estos métodos cuantitativos deben ser usados para todos los productos de la empresa dada la notable mejora

en la precisión. Esta investigación aporta con los resultados de haber aplicado métodos puramente matemáticos para el pronóstico de la demanda, y al haber usado métricas comunes en este tipo de tareas además de mostrar el registro histórico de los pronósticos generados junto con un análisis de los parámetros adecuados para cada técnica, se podrá medir la diferencia con los métodos del Machine Learning.

### *Antecedentes nacionales*

Calderón [15] expone que la empresa donde aplicó una de sus investigaciones tiene sucursales en varios países y en cada una de ellas cuenta con un área encargada de la planificación de la demanda. La sucursal que analizó importaba el 90% de sus productos, por este motivo la planificación de la demanda debía ser sumamente precisa para en primer lugar evitar quiebres de stock y en segundo lugar minimizar los costos que se puedan generar al realizar varias solicitudes de importación en un mismo periodo. Durante el periodo de análisis se identificó que a raíz de la pandemia por el Covid-19 el comportamiento había variado drásticamente y sus pronósticos no se ajustaban a lo que realmente sucedía y por esta razón presentó una propuesta de mejora que incluía la implementación del método de clasificación de inventarios ABC y la evaluación de los pronósticos generados con los métodos: Promedio móvil, regresión lineal, suavización exponencial simple y suavización exponencial doble para identificar cuál de estos métodos ayudaría a solucionar la problemática. Después de la medición del error generado por cada uno de estos modelos para 7 productos se obtuvieron los siguientes errores cuadráticos medios (MSE por sus siglas en inglés): 51, 43.6, 42.6, 38.6, 29.9, 37.1 y 53.7, para los mismos productos, el error porcentual absoluto medio (MAPE por sus siglas en inglés) fue: 8.3%, 8.7%, 15.6%, 10.7%, 23.3%, 26.5% y 12.8%. Con estos resultados el autor estima que se podrá mantener un porcentaje de quiebres de stock menor al 1.5% y generar una tasa interna de retorno (TIR) del 35%, asimismo, recomienda replicar este proceso de mejora en todos los productos con la mayor cantidad de datos históricos posibles y en general realizar un seguimiento continuo para monitorear y corregir, en caso sea necesario, los pronósticos que se van generando a fin de cumplir con las expectativas de mejora. Este antecedente fue considerado como tal porque aporta un análisis individual y luego general de las métricas de error comunes en este tipo de problemas como el MSE y MAPE mencionados anteriormente, y otras más como la desviación media absoluta (MAD) y la suma acumulada de errores de pronóstico (CFE), además, muestra a detalle el procedimiento seguido para el uso de los métodos de pronóstico incluyendo por ejemplo el uso del coeficiente de correlación



Pearson y el coeficiente de determinación para corroborar la validez de los pronósticos generados con el método de regresión lineal.

Mamani [16] expone la necesidad que tenía una empresa de contar con una predicción de las ventas mensuales, ya que necesitaba abastecerse adecuadamente de los productos más solicitados en cada campaña para mantenerse dentro del margen de competitividad del mercado, por ello el autor propuso que a través del uso de la metodología Box Jenkins se construyera y validara un modelo que utilice el esquema ARIMA para predecir la demanda. El autor analizó diferentes variantes de los modelos AR, MA, ARMA y ARIMA, cada uno de ellos con la misma serie temporal compuesta por 102 datos mensuales que comprendían el periodo del año 2009 al año 2017, con esto logró identificar al modelo ARIMA univariante multiplicativo integrado como el tipo de modelo adecuado para el problema que estaba tratando, con dicho modelo generó los pronósticos para 24 meses con un 95% de confianza. Finalmente recomienda que para futuros trabajos se considere utilizar una serie temporal de mayor tamaño y mejor amplitud, además que el proceso debería repetirse cada cierto tiempo para mantener un índice de confianza aceptable. Esta investigación fue incluida en los antecedentes debido a que analiza a profundidad las posibilidades de los modelos ARIMA para realizar los pronósticos de la demanda y sumado a ello en su investigación muestra a profundidad y de forma práctica el análisis de la presencia de estacionalidad en series temporales, del cálculo de los coeficientes de autocorrelación y como todo ello podría influir en la sobre parametrización y sobre diferenciación de los modelos.

Robles y Valverde [17] describen el problema de la falta de stock en una empresa automotriz y afirman que esta escasez ocasiona que no se puedan concretar las ventas, por esta razón proponen utilizar las Redes Neuronales Recurrentes (RNN por sus siglas en inglés) para generar predicciones de la demanda de repuestos y accesorios automotrices. Los autores optaron por utilizar la metodología de desarrollo Rational Unified Process (RUP), esto después de una comparación entre metodologías tradicionales y ágiles, además, dentro de la metodología RUP incluyeron la metodología CRISP-DM para manejar el proceso de construcción de la RNN. La construcción de esta RNN se realizó utilizando la librería Keras y tomando como referencia el modelo secuencial que esta incluye, en cuanto a las capas, estas fueron de los tipos Long Short-Term Memory (LSTM) y Dense. También buscaron adaptar un sistema de apoyo a la gestión de logística para lo cual realizaron una comparación de los sistemas existentes en el mercado y concluyeron que el sistema Tryton era el adecuado. Finalmente, los autores calcularon que el modelo desarrollado tenía un margen de error de entre el 15% y 40% con una frecuencia entre 0.01 y 0.08 por predicción, siendo lo más común

una predicción con un error del 22% en una frecuencia de 0.08. El aporte de esta tesis por el que fue seleccionada como antecedente está en que muestra a detalle el uso del Machine Learning para solucionar problemas de pronóstico de demandas y explica el proceso para el mantenimiento continuo y semiautomático de la RNN que construyó.

### *Antecedentes locales*

Montenegro [18] analiza en su tesis la problemática de una botica que llevaba un mal manejo de inventarios y ello le ocasionaba una rentabilidad baja, en esta situación la autora propuso encontrar un método para predecir las ventas de los fármacos de la línea de cardiología. Para estos fines se optó por clasificar los medicamentos utilizando el método ABC y seleccionar aquellos que pertenezcan al grupo A, es decir, los medicamentos de mayor rotación, luego, para cada uno de estos medicamentos se recolectaron los datos históricos de sus ventas desde Julio del 2014 hasta Julio del 2017 y se procesaron utilizando los programas estadísticos Minitab y Cristal Ball, posteriormente se aplicaron los métodos de pronóstico ARIMA, promedio móvil simple, promedio móvil doble y suavización exponencial con sus respectivas métricas de evaluación, logrando determinar el modelo adecuado para cada fármaco, los modelos seleccionados fueron el promedio móvil doble y ARIMA, el primero de ellos fue utilizado para un medicamento al haber obtenido un MAPE de 15.19% y un RMSE de 24.46 con dicho medicamento, por otro lado, el modelo ARIMA fue utilizado para tres medicamentos al haber obtenido un MAPE de 11.13%, 8.24% y 9.17% y un RMSE de 10.82, 8.81 y 16.59 respectivamente. Con estos modelos se generaron pronósticos de las ventas de 12 meses para los cuatro medicamentos que se categorizaron en el grupo A. Esta tesis se incluyó como antecedente porque brinda una perspectiva alternativa no excluyente para la evaluación de los métodos utilizados en la generación de los pronósticos de la demanda, esta perspectiva consiste en el análisis de la autocorrelación de los residuos de pronóstico para detectar aleatoriedad o estacionalidad y la ejecución de una prueba de normalidad basada en el P-value para determinar si los residuos siguen o no una distribución normal.

Benites [19] por su parte trata la ausencia de un sistema de pronóstico de demanda en una empresa dedicada a la producción y comercialización de productos del rubro de construcción, argumenta que la existencia del mencionado sistema ayudaría a los directivos de la empresa a mejorar el proceso de toma de decisiones, asimismo señala que se debe tener extremo cuidado durante su implementación para garantizar la seguridad de la información y la precisión de los pronósticos generados. El autor propuso utilizar la metodología de diseño de ocho pasos propuesta por Kaastra & Boyd [20] para generar los pronósticos de la demanda a través de

una red neuronal artificial, específicamente del tipo perceptrón multicapa, combinada con el análisis de regresión de series temporales mediante datos de ventana con desplazamiento, por otro lado, planteó emplear el lenguaje de programación C# para construir el sistema que permitiría a los usuarios acceder a los pronósticos. Tras recopilar los registros históricos de las ventas desde el año 2016 hasta el año 2017 inició el entrenamiento de la red neuronal artificial conformada por cuatro neuronas en la capa de entrada, una capa oculta con doce neuronas y una neurona en la capa de salida. Posteriormente realizó la evaluación del modelo construido y obtuvo que para los pronósticos desde enero hasta julio del año 2018 se tenía una confianza de 99.71%, 95.22%, 93.63%, 94%, 92.17%, 93.90% y 92.34% respectivamente. Esta investigación aporta como antecedente al detallar la arquitectura de la red neuronal, el código utilizado para su implementación, la estructura de los datos, el proceso de normalización y los registros obtenidos durante el proceso de entrenamiento tales como los pesos asignados en cada neurona, vale la pena resaltar especialmente las rutinas de programación ya que estas muestran una implementación desde cero y permiten entender por completo el funcionamiento interno de la red neuronal partiendo desde la inicialización de los 73 pesos sinápticos que conformaron su red hasta el procedimiento encargado de generar los pronósticos.

Azañero y Ramírez [21] estudiaron en una de sus investigaciones la importancia de la estimación de las ventas futuras en las empresas Ferreteras que quieran ser competitivas en el mercado, por ello presentaron un análisis comparativo de los métodos existentes para el pronóstico de la demanda entre los cuales se encontraron el promedio móvil, el suavizado exponencial simple, los modelos ARIMA, el modelo Adaptive neuro fuzzy inference system (ANFIS) y las redes neuronales artificiales. Los autores realizaron en primer lugar una comparación teórica que abarcó puntos como el objetivo del método, sus características, procedimiento y posibles aplicaciones, así como las ventajas y desventajas de cada uno, posteriormente se ejecutó una comparación práctica en la cual la red neuronal artificial obtuvo el un MAPE del 20%, mismo que fue el menor entre todos los métodos comparados, además obtuvo un MAD de 3.98, un MSE de 22.08 y un error medio porcentual (MPE por sus siglas en inglés) de 0.20. Esta investigación se encuentra dentro de los antecedentes por la exhaustiva comparación que realiza entre las métricas de evaluación de cada método probado, ya que esto combinado con la interpretación de la serie de datos permite inferir los contextos en los que cada método sería efectivo al igual que el sesgo presente en cada métrica.

## ***Bases teóricas***

### ***Aplicación web***

El desarrollo web trae muchas ventajas, entre ellas está el hecho de que las aplicaciones y sistemas que se construyan estarán disponibles en cualquier parte del mundo por lo que sus usuarios sólo necesitan contar con un dispositivo que tenga acceso a internet para continuar interactuando con las aplicaciones [22].

Este tipo de aplicaciones se seleccionó para la ejecución de esta investigación por la ventaja de disponibilidad que se mencionó anteriormente, además de ello porque permitió centralizar el procesamiento de datos en equipos que estén preparados para ello y disminuir las características mínimas requeridas en los dispositivos de los usuarios finales.

### ***Componentes de una aplicación web***

Es importante conocer los componentes de una aplicación web ya que analizando la interrelación entre cada uno de ellos se podrá realizar una mejor planificación de las tecnologías a utilizar.

- Base de datos: Se utiliza para almacenar los datos de los usuarios de la aplicación como por ejemplo sus credenciales de acceso, preferencias, entre otros. Actualmente existen muchos gestores de base de datos y pueden ser de tipo SQL y NoSQL, cada uno con distintas orientaciones. Entre los gestores más conocidos encontramos Mongo DB para bases de datos de tipo NoSQL [23] y PostgreSQL para bases de datos de tipo SQL [24].
- Backend: Este componente es muy importante dentro de las aplicaciones web pues en él recae la responsabilidad de mantener segura la transferencia de información entre la base de datos y la interfaz con la cual interactúa el usuario, aquí se realizan validaciones de los datos recibidos para asegurar la veracidad e integridad de la información dentro de los sistemas. Un backend puede ser construido con diferentes herramientas, entre ellas Javascript [25], PHP [26] y Python [27]:
- Interfaz de usuario: Es la parte visual e interactiva de la aplicación, también conocida como Frontend. La estructura de sus elementos es interpretada por el navegador a través del lenguaje de marcado HTML (HyperText Markup Language), CSS (Cascading Style Sheets) se utiliza para dar estilos a estos mismos elementos mientras que Javascript sirve para dotarlos de funcionalidad e interactividad. A pesar de que el

navegador sólo interpreta los lenguajes mencionados, existen marcos de referencia que permiten construir las interfaces con lenguajes de programación, por ejemplo, Laravel permite utilizar el lenguaje PHP, NextJs por su parte permite el uso de Javascript y Django el de Python.

La revisión de estos componentes permitió tener un acercamiento a las tecnologías utilizadas para construirlos, asimismo, en base al conocimiento que se tenía del problema y los requerimientos para la solución, se compendió la importancia de cada uno de ellos y se plantearon algunas condiciones como por ejemplo que no utilizaría una sola base de datos sino que se integraría a la arquitectura la base de datos del sistema transaccional que utiliza la empresa para el registro de sus ventas, esto con la finalidad de alimentar el sistema de pronóstico en tiempo real. Por otro lado, tanto el backend como el frontend serán independientes entre sí e independientes al sistema transaccional que se mencionó anteriormente dado que principalmente el backend podría necesitar una alta capacidad de procesamiento y se quiere evitar que ello repercuta en el rendimiento del sistema transaccional, la independencia entre sí busca que en caso de que se necesite aumentar la capacidad de procesamiento del backend se pueda utilizar realizar un escalado sólo de este componente.

### *Arquitecturas de aplicaciones*

Existen diversos diseños para las arquitecturas de las aplicaciones, dos de los más conocidos son la arquitectura monolítica y la basada en microservicios [28], además de estas podemos encontrar otras como la arquitectura en capas, basada en eventos, orientada al servicio, shared-disk, shared-memory, shared-nothing [29] y varias más [30]. A continuación, se describirán algunas de las ya mencionadas:

Para esta investigación será importante seleccionar la arquitectura adecuada, esta decisión debe estar basada en los requerimientos y objetivos que se persiguen con la construcción del sistema más que en las preferencias personales o diferencias entre cada una, por ejemplo, la arquitectura basada en microservicios ofrece flexibilidad para escalar la aplicación, sin embargo para casos de aplicaciones pequeñas que no se pretende actualizar o que crezcan en complejidad sería una inversión innecesaria de esfuerzo. Por otro lado, como ya se ha visto en el análisis de los componentes de una aplicación web, los marcos de referencia de desarrollo pueden incluir una propuesta de arquitectura para la aplicación y esto también deberá ser tomado en cuenta.

## *Minería de datos*

La minería de datos es utilizada para preparar y explorar los datos con la finalidad de encontrar información oculta que sea útil para los diferentes fines que persigan cada proyecto [31]. Dentro de la minería de datos existen diversas tareas tales como el análisis de cestas de compra, la identificación de patrones de deserción, la detección de fraude, la generación de pronósticos y muchas otras. Para la ejecución de estas tareas se pueden utilizar técnicas puramente estadísticas, técnicas del campo de la inteligencia artificial o combinaciones de ambas, a continuación, se explicarán las técnicas resaltantes para el problema de esta investigación:

### *Técnicas de pronóstico*

- **Redes neuronales:** Se les conoce como redes neuronales artificiales y en ocasiones como sistemas conexionistas, pero en general se refieren a sistemas de procesamiento de datos que emulan el funcionamiento de una red neuronal biológica, así, su estructura está compuesta por nodos que se conectan entre sí para transferirse datos y a la vez mantienen un valor denominado peso que es modificado durante el proceso de entrenamiento con la finalidad de lograr que el resultado final sea lo más parecido posible al resultado esperado [32].

Existen diferentes tipos de redes neuronales artificiales, entre ellos el perceptrón simple [33], el perceptrón multicapa [33], la red neuronal convolucional [34] y otros:

Para el caso que se está analizando en esta investigación las redes neuronales artificiales se ven atractivas ya que la cantidad de medicamentos con la que se cuenta en una farmacia es variable pero siempre alta y los modelos de redes neuronales artificiales podrían auto ajustarse para obtener los mejores resultados y así ahorrar tiempo. En cuanto a los diferentes tipos de red que existen será necesario evaluar la complejidad de cada serie temporal y en función de ello seleccionar el tipo adecuado.

- **Modelos ARIMA:** ARIMA es el acrónimo de Autoregressive Integrated Moving Average [35]. Estos modelos permiten describir los valores de una variable a través de una función lineal inferida del comportamiento de los datos históricos [36], la función calculada incluye tres parámetros: El orden de retraso ( $p$ ), el grado de diferenciación ( $d$ ) y el orden de media móvil ( $q$ ) [37].

Para efectos de esta investigación resultó interesante analizar la existencia varios antecedentes donde estos modelos están presentes y obtienen resultados aceptables, en

algunas ocasiones superados por otra técnica de pronóstico, pero en líneas generales tras la revisión de las comparaciones y resultados, así como de la propia teoría de estos modelos queda claro que su rendimiento está en función de las características que tenga cada serie temporal.

- Modelos de suavizado exponencial: Es otro de los modelos utilizados para el pronóstico de la demanda de series temporales, este modelo produce una serie de datos suavizados partiendo de un conjunto de datos históricos [38]. Es importante resaltar que este modelo resulta interesante ya que brinda mayor peso a los registros recientes sobre los más antiguos permitiendo obtener pronósticos con pocos datos, esto representa una ventaja sobre otros modelos para ser aplicado en pequeñas empresas.

### *Métricas de evaluación de rendimiento*

Una vez vistas las técnicas utilizadas dentro de la minería de datos, es preciso hablar sobre las métricas que permiten evaluar el rendimiento de cada una de ellas, a continuación, se presentarán algunas de las principales:

- El error cuadrático medio (MSE) es la manera más habitual de evaluar un modelo de regresión. Mediante esta medida se calculan las diferencias entre los valores pronosticados por el modelo o un estimador y los valores reales a partir de los cuales se ha creado el modelo. El error cuadrático medio es una medida de la media de los cuadrados de los errores. Por error se entiende la diferencia entre el valor estimado y el valor real [39]. El error cuadrático medio se calcula de la siguiente manera:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- El error absoluto medio (MAE) es otra forma de evaluar la calidad en los modelos de regresión. Al igual que el error cuadrático medio, esta medida también sirve para calcular la diferencia entre las predicciones hechas por un estimador y los valores reales. La diferencia entre ambas surge del principal problema que tiene calcular el error cuadrático medio, y es que al elevar al cuadrado la diferencia se tiende a dar demasiado peso a los errores más extremos, afectando al resultado final, utilizando el error absoluto medio se puede limitar este problema [40]. La fórmula para calcular el error absoluto medio es la siguiente:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- R-cuadrado También conocido como coeficiente de determinación, representa la bondad de un modelo para ajustarse a la variable que desea explicar, de forma más técnica se le puede definir como la proporción de la varianza total [41]. Mientras mayor sea su valor mejor será el ajuste del modelo a la variable, sin embargo, la búsqueda de un R-cuadrado máximo podría tener como resultado la aceptación de un modelo con el problema de “Sesgo preprueba” [42]. Figueiredo, Silva y Rocha [43], coinciden en afirmar que esta métrica presenta algunas limitaciones cuando se usa para seleccionar un modelo de pronóstico debido a que varía en función de la cantidad de predictores que se utilizan.

La fórmula utilizada para su cálculo es la siguiente:

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2}$$

En cuanto a su interpretación, Alhyari [44] propone la siguiente escala:

*Tabla 1. Escala para R-Cuadrado*

Valor	Clasificación
R-cuadrado < 0.3	Adaptación nulo o muy débil
0.3 < R-cuadrado < 0.5	Adaptación débil o bajo
0.5 < R-cuadrado < 0.7	Adaptación moderada
R-cuadrado > 0.7	Adaptación fuerte

- MAPE es la representación porcentual de la desviación, es decir, la diferencia entre la demanda real y el pronóstico [45]. La fórmula utilizada para su cálculo es la siguiente:

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right|}{N}$$

En cuanto a su interpretación, Lewis [46] propone la siguiente escala:

*Tabla 2. Escala para MAPE*

Valor	Clasificación
MAPE < 10%	Excelente
10% ≤ MAPE < 20%	Bueno
20% ≤ MAPE < 50%	Razonable
MAPE ≥ 50	Inexacto

## ***Demanda***

El término demanda hace referencia a la cantidad de un producto o frecuencia con la que un servicio será solicitado o adquirido por un grupo de usuarios dentro de un lugar y tiempo determinado [47].



Este concepto es muy importante dentro de la planificación de abastecimiento que realizan las empresas, específicamente la farmacia de un establecimiento de salud para el caso de esta investigación, ya que a través del estudio del comportamiento que tuvo la demanda en tiempos pasados en combinación con el análisis del mercado se puede realizar proyecciones de una posible demanda futura y abastecerse en función de ella, sin embargo, no siempre es tomada en cuenta ya sea por la ausencia de personal capacitado o por la imposibilidad de analizar toda la información disponible.

### ***Planificación del abastecimiento en la farmacia***

Fue relevante recopilar información sobre el proceso de abastecimiento que se tenía dentro de la farmacia del establecimiento de salud donde se ejecutó esta investigación, de dicho análisis se pudo conocer el personal encargado de la gestión de la farmacia junto con el gerente general son partícipes del proceso de planificación de abastecimiento, mismo que se realiza en base al análisis del plan de abastecimiento y registro de ventas del periodo anterior, al conocimiento empírico que se recopile del funcionamiento de la farmacia y a los objetivos y metas comerciales que se hayan propuesto. Las razones de no utilizar un análisis de todos los periodos anteriores son que en primer lugar no se cuenta con un sistema capaz de analizar tal volumen de información, además, la experiencia con este proceso sumada al conocimiento empírico que han generado les permite deducir que, dada la naturaleza variable del mercado, el uso de sólo el último periodo permite tener resultados aceptables [8].

### ***Factores determinantes de la demanda***

La variación de la demanda puede estar determinada por diversos factores, además, estos se pueden clasificar según si pueden ser controlados por la empresa o no [48]. Entre los factores determinantes de la demanda que la empresa puede controlar encontramos el precio, la comunicación y el producto. Por otro lado, entre los factores determinantes que la empresa no puede controlar tenemos las variables del consumidor, variables de la competencia y variables del macroentorno [49]:

Algunas de estas variables ya eran consideradas en el proceso de planificación de abastecimiento de la farmacia del establecimiento de salud donde se aplicó esta investigación, sin embargo, hasta donde se conoció estos eran analizados sin un registro histórico o herramientas especializadas, en su lugar se utilizaban estimaciones basadas en la experiencia.

### ***Pronóstico de la demanda***

La importancia del pronóstico de la demanda radica en la ayuda que brinda para la planificación del abastecimiento. Para las empresas es importante mantener la cantidad apropiada de stock ya que de esta manera se evitará que los productos pasen mucho tiempo en almacén o por el contrario no existan suficientes para satisfacer la demanda [50].

### **III. Metodología**

A continuación, se detallará la información relevante para el diseño de la investigación:

#### ***Tipo de investigación***

Según el fin que se persigue, la investigación fue de tipo aplicada, que según José Lozada busca generar conocimiento y aplicarlo a la brevedad sobre problemas prácticos de la sociedad u organizaciones [12].

Para la contrastación de la hipótesis se utilizará la investigación cuasi experimental ya que se contará con un solo grupo de control [13].

#### ***Métodos de investigación***

En esta investigación se usarán los siguientes métodos:

*Tabla 3. Métodos de investigación*

Método	Descripción
Analítico	Este método se utilizará para analizar la situación actual de la empresa junto a las causas y consecuencias del problema.
Sintético	Será útil para el proceso de construcción de la solución propuesta donde se combinarán los conocimientos del área problemática y los conocimientos de las tecnologías a emplear.
Implementación	Servirá para la puesta en marcha de la solución.

#### ***Técnicas e instrumentos de recolección de datos***

Dada la necesidad de obtener información confiable, se propusieron las siguientes técnicas e instrumentos:

*Tabla 4. Técnicas e instrumentos de recolección de datos*

Técnicas	Instrumentos	Elementos de la población	Propósito
Entrevista	Guía de Entrevista	Jefa de ventas y almacén	Obtener información relevante sobre los procesos de venta y abastecimiento.
Revisión bibliográfica	Ficha de registro	Documentación del proceso de abastecimiento	Identificar deficiencias y oportunidades en el proceso de pronóstico de la demanda.
Revisión documental	Lista de cotejo	Bases de datos	Explorar, evaluar y seleccionar los conjuntos de datos relevantes para la construcción de la solución.
Registro Documental	Ficha de registro	Jefa de ventas y almacén	Implementar adecuadamente la solución en el entorno de producción.

#### IV. Resultados

Con la planificación realizada se logró construir una solución capaz de pronosticar la demanda de medicamentos en la farmacia del establecimiento de salud, dicha solución se construyó utilizando la siguiente arquitectura:

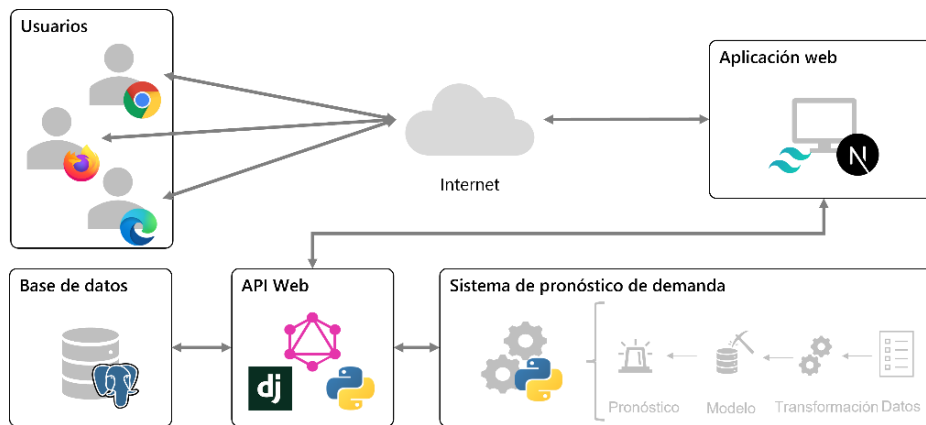


Figura 1. Arquitectura de la solución

A continuación, se detallarán los resultados obtenidos tras la ejecución de lo propuesto en esta investigación:

#### *Resultados en base a los objetivos*

**OE1: Alcanzar un valor mayor a 0.6 en el nivel de adaptación del modelo de pronóstico a la demanda de medicamentos en la farmacia de un establecimiento de salud.**

El primer objetivo fue propuesto con la finalidad de que los modelos de pronóstico que se construyan se adapten con la mayor precisión posible al comportamiento de la demanda independientemente de si esta presenta características estacionales o no.

El indicador para este objetivo fue la adaptación del modelo al comportamiento de la demanda y para medirlo se utilizó la métrica del coeficiente de determinación o también conocido como R-Cuadrado que se calcula de la siguiente manera:

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2}$$

Donde:

- $N$  = Cantidad de pronósticos generados.
- $x_i$  = Demanda real.
- $\hat{x}_i$  = Demanda pronosticada.
- $\bar{x}$  = Media de la demanda real.

De su representación matemática se entiende que esta métrica representa la bondad de un modelo para ajustarse a la variable que desea explicar. De forma más técnica se le puede definir como la proporción de la varianza total [41] y por ello mientras mayor sea su valor mejor será el ajuste del modelo a la variable [42]. En cuanto a los valores que puede tomar, R-cuadrado está delimitado de la siguiente forma:

$$0 \leq \text{R-cuadrado} \leq 1$$

Sin embargo, por su fórmula matemática, en casos donde el modelo genera pronósticos más lejanos a los valores reales que la media de estos, R-cuadrado podría ser un número negativo e incluso tender a  $-\infty$ .

El cálculo de esta métrica se dio durante la etapa de evaluación de modelos de la metodología CRISP-DM y se utilizó la función “r2\_score” de la librería “sklearn”, para facilitar esta tarea se construyó la siguiente función:

```
from sklearn.metrics import r2_score

# Scalers is a dictionary of MinMaxScaler objects for each product
# x_train and y_train are a dictionaries of train datasets for each product

def inverse_transform(prod, values):
    return scalers[prod].inverse_transform(values)

def calculate_r2(prod):
    y_true = inverse_transform(prod, y_train[prod].values.reshape(-1,1))
    y_pred = inverse_transform(prod, models[prod]['model'].predict(x_train[prod]))
    r2 = r2_score(y_true, y_pred)

    return r2
```

Figura 2. Función calcular el valor R-Cuadrado del modelo

La función que se muestra arriba se utilizó para obtener los indicadores de un modelo en particular, adicionalmente, para verificar el cumplimiento del objetivo se elaboró la siguiente función:

```
import json

for i in products.index.tolist():
    with open(f'models/{i}.json', 'r') as fp:
        model_info = json.load(fp)

    r2 = model_info['r2']
    if(r2 > 0.6):
        if (r2 > 0.6 and r2 < 0.7):
            models_r2_60 += 1
        elif (r2 ≥ 0.7 and r2 < 0.8):
            models_r2_70 += 1
        elif (r2 ≥ 0.8 and r2 < 0.9):
            models_r2_80 += 1
        elif (r2 ≥ 0.9):
            models_r2_90 += 1
        r2_approved_models.append(i)
    else:
        r2_disapproved_models.append(i)
```

Figura 3. Función para evaluar R-Cuadrado en todos los modelos

En la primera evaluación se obtuvo que no todos los modelos cumplían con los criterios de éxito y por ende se procedió a reentrenar los modelos variando los parámetros hasta que finalmente se pudo corroborar que todos los modelos habían obtenido un valor de R-cuadrado mayor a 0.6.

```

Evaluación de R2
-----
R2>0.6: 14449
R2≤0.6: 0

Detalle de los modelos
-----
R2 mayor o igual a 0.9: 8871
R2 mayor o igual a 0.8: 1992
R2 mayor o igual a 0.7: 2015
R2 mayor a 0.6: 1571

```

Figura 4. Resultados del primer objetivo

De la imagen anterior ya se puede observar que la mayoría de los modelos obtuvieron una adaptación mayor o igual a 0.9 y para un mejor análisis de ello se generó el siguiente gráfico que utiliza intervalos más pequeños:

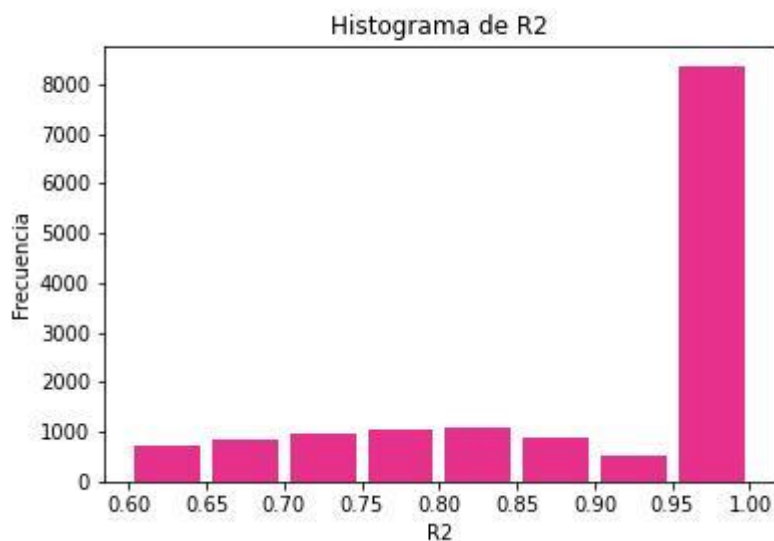


Figura 5. Histograma de los resultados del primer objetivo

Finalmente se generó un resumen de las medidas de tendencia central y los valores mínimo y máximo como se puede apreciar en la siguiente tabla:

Tabla 5. Resumen de los resultados del primer objetivo

Medida	Valor
Media	0.903348
Mediana	0.999518
Moda	0.9999
Mínimo	0.600003
Máximo	1

***OE2: Lograr un porcentaje menor a 40% en el error de precisión del pronóstico de la demanda de medicamentos en la farmacia de un establecimiento de salud.***

Este objetivo buscaba asegurar el correcto funcionamiento de los modelos dado que si bien con el primer objetivo se garantizaba que el modelo se haya ajustado a la demanda, ello no aseguraría que los pronósticos que se generen sean precisos, esto porque entre los problemas del Machine Learning se encuentra el overfitting que hace referencia a la situación en la que los modelos producen buenos resultados sólo con datos parecidos a los que se usaron para su entrenamiento pero su rendimiento decrece cuando se le ingresan datos nuevos.

El indicador de este objetivo fue el porcentaje de error calculado con la métrica MAPE que se obtiene de la siguiente manera:

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right|}{N} \times 100$$

Donde:

- $x_i$  = Demanda actual.
- $\hat{x}_i$  = Demanda pronosticada.
- $N$  = Cantidad de pronósticos generados.

Se debe entender el MAPE como la representación porcentual de la desviación, es decir, la diferencia porcentual entre la demanda real y el pronóstico [45]. MAPE está delimitado de la siguiente forma:

$$0\% \leq MAPE \leq 100\%$$

Con relación a esta métrica es importante tener en cuenta que va a variar según la cantidad de datos y los valores que estos tomen [51], además, en algunos casos es asimétrica, es decir, penaliza mucho más los sobre pronósticos que las subestimaciones y, por la misma naturaleza de su fórmula, toma valores indefinidos cuando la demanda real es cero, y valores extremos cuando se aproxima a cero [52].

Se esperaba que los modelos generados en este proyecto cumplan con obtener un MAPE menor a 40% y para comprobarlo, al igual que con el objetivo anterior, se utilizó la librería “sklearn” pero esta vez con la función “mean\_absolute\_percentage\_error”. A continuación, se muestra la función encargada de calcular esta métrica:

```

from sklearn.metrics import mean_absolute_percentage_error

# Scalers is a dictionary of MinMaxScaler objects for each product
# x_test and y_test are a dictionaries of test datasets for each product

def inverse_transform(prod, values):
    return scalers[prod].inverse_transform(values)

def calculate_mape(prod):
    y_true = inverse_transform(prod, y_test[prod].values.reshape(-1,1))
    y_pred = inverse_transform(prod, models[prod]['model'].predict(x_test[prod]))
    mape = mean_absolute_percentage_error(y_true, y_pred)*100

    return mape

```

Figura 6. Función para calcular el valor MAPE del modelo

Luego de calcular el MAPE para cada modelo se realizó una clasificación según el valor obtenido, para ello se utilizó la siguiente función:

```

for i in products.index.tolist():
    with open(f'models/{i}.json', 'r') as fp:
        model_info = json.load(fp)

    mape = model_info['mape']
    if(mape < 40):
        if (mape < 40 and mape > 30):
            models_mape_40 += 1
        elif (mape ≤ 30 and mape > 20):
            models_mape_30 += 1
        elif (mape ≤ 20 and mape > 10):
            models_mape_20 += 1
        elif (mape ≤ 10):
            models_mape_10 += 1
        mape_approved_models.append(i)
    else:
        mape_disapproved_models.append(i)

```

Figura 7. Función para evaluar MAPE en todos los modelos

Los resultados que se obtuvieron al principio no cumplían con lo esperado, sin embargo, después de los reentrenamientos, hubo modelos con un MAPE incluso menor o igual al 10% además de que todos cumplieron con el criterio de aceptación planteado en este objetivo tal como se muestra a continuación:

```

Evaluación de MAPE
-----
MAPE<40%: 14449
MAPE ≥ 40%: 0

Detalle de los modelos
-----
MAPE menor o igual a 10%: 604
MAPE menor o igual a 20%: 9461
MAPE menor o igual a 30%: 3960
MAPE menor a 40%: 424

```

Figura 8. Resultados de la evaluación del segundo objetivo

Al igual que con el objetivo anterior, se generó un histograma de los resultados con intervalos más pequeños y esta vez se detectó que la mayor parte de los modelos tuvieron un MAPE entre 10% y 25%:

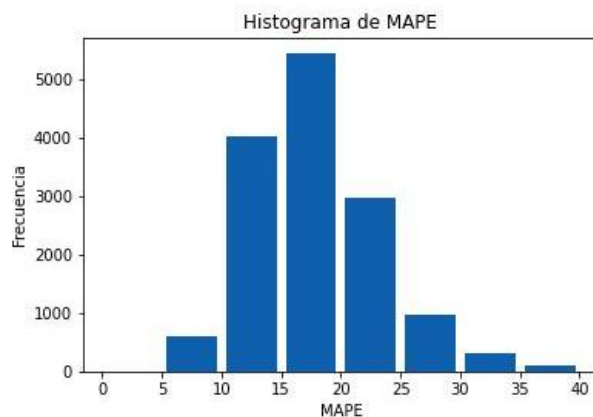


Figura 9. Histograma de los resultados del segundo objetivo

También se realizó el análisis de las medidas de tendencia central y los resultados se muestran en la siguiente tabla:

Tabla 6. Resumen de los resultados del segundo objetivo

Medida	Valor
Media	17.8759
Mediana	17.182
Moda	14.4974
Mínimo	5.07698
Máximo	39.9936

**OE3: Obtener una puntuación mayor a 90% en la evaluación de rendimiento de la aplicación web utilizando una herramienta de medición de rendimiento.**

El tercer objetivo estuvo orientado a obtener un buen rendimiento de la aplicación web a fin de garantizar que la experiencia de los usuarios del sistema sea la mejor posible ya que de lo contrario no podrían interactuar con los modelos de pronóstico. Para medir el cumplimiento de este objetivo se consideró la métrica proporcionada por la herramienta “Lighthouse”, misma que se calcula de la siguiente manera:

$$\text{SCORE} = 0.1(\text{FCP}) + 0.1(\text{SI}) + 0.25(\text{LCP}) + 0.1(\text{TTI}) + 0.3(\text{TBT}) + 0.15(\text{CLS})$$

Donde:

- FCP = First Contentful Paint
- SI = Speed Index
- LCP = Largest Contentful Paint
- TTI = Time to Interactive
- TBT = Total Blocking Time
- CLS = Cumulative Layout Shift



Así mismo, para cada ítem anterior se tienen definidas las escalas cualitativas que se muestran en la siguiente tabla:

Tabla 7. Escala cualitativa para ítems del rendimiento

Ítem	Unidad	Escala	Valoración
First Contentful Paint	Segundos	0 - 1.8	Rápido
		1.8 - 3	Moderado
		Más de 3	Lento
Speed Index	Segundos	0 - 3.4	Rápido
		3.4 - 5.8	Moderado
		Más de 5.8	Lento
Largest Contentful Paint	Segundos	0 - 2.5	Rápido
		2.5 - 4	Moderado
		Más de 4	Lento
Time to Interactive	Segundos	0 - 3.8	Rápido
		3.9 - 7.3	Moderado
		Más de 7.3	Lento
Total Blocking Time	Milisegundos	0 - 200	Rápido
		200 - 600	Moderado
		Más de 600	Lento
Cumulative Layout Shift	Unidad	0 - 0.1	Rápido
		0.1 - 0.25	Moderado
		Más de 0.25	Lento

Adicionalmente a las escalas cualitativas mostradas es necesario asignar un puntaje cuantitativo para poder calcular la métrica, estos puntajes están distribuidos en una curva logarítmica normal que tiene la siguiente fórmula:

$$M(x) = 1 - \frac{1}{2} \left( 1 + \operatorname{Erf} \left( \frac{\ln(x) - b}{a\sqrt{2}} \right) \right)$$

Donde:

- $a = \frac{1}{2} \sqrt{1 - 3 \ln \left( \frac{p}{m} \right) - \sqrt{\left( \ln \left( \frac{p}{m} \right) - 3 \right)^2 - 8}}$
- $b = \ln(m)$

Tanto para el cálculo de “a” como de “b” se utilizan dos constantes que depende de la métrica que se calculará, estas constantes son:

- m = Mediana
- p = Punto de rendimiento decreciente

En M(x) se hace uso de otra función que se basa en una de las propuestas de Abramowitz y Stegun [53] para calcular el error, la definición de la fórmula adaptada es la siguiente:

$$\operatorname{Erf}(x) = \sin(x) \left( 1 - \left( \left( \left( \left( (1.061405429 \cdot t_{AS}(x) + -1.453152027) \cdot t_{AS}(x) \right) + 1.421413741 \right) \cdot t_{AS}(x) + -0.284496736 \right) \cdot t_{AS}(x) \right. \right. \\ \left. \left. + 0.254829592 \right) \cdot t_{AS}(x) \cdot \exp(-(x \cdot x)) \right)$$

Nuevamente en esta fórmula encontramos una referencia a otra función que se define como:

$$t_{AS}(x) = \frac{1}{1 + 0.3275911 |x|}$$

Finalmente, como se mencionó al principio, en el cálculo de “a” y “b” en  $M(x)$  se utilizan constantes “m” y “p” diferentes para cada métrica, estas se detallan a en la siguiente tabla:

*Tabla 8. Valores para las variables "m" y "p"*

Ítem	Punto de rendimiento decreciente (p)	Mediana (m)
First Contentful Paint	2000	4000
Speed Index	2900	5800
Largest Contentful Paint	2000	4000
Time to Interactive	2900	7300
Total Blocking Time	200	600
Cumulative Layout Shift	0.054	0.25

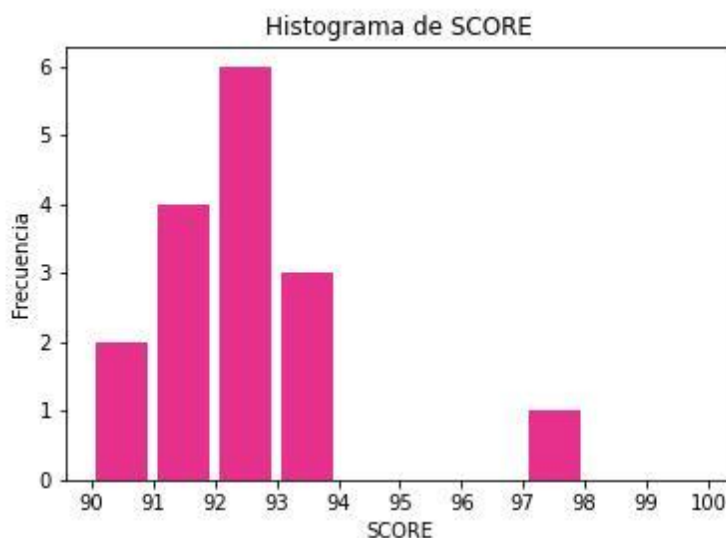
Al concluir el cálculo individual de cada ítem se aplicará la ponderación que se mostró inicialmente y a dicho resultado se le clasificará según esta nueva escala:

*Tabla 9. Escala para la evaluación del rendimiento*

Valor	Clasificación
0 - 49	Deficiente
50 - 89	Necesita mejorar
90 - 100	Bueno

El objetivo en este proyecto fue obtener una puntuación mayor al 90%, que en esta escala corresponde a 90 puntos. Para ejecutar el cálculo de esta métrica se utilizó “Lighthouse” que está disponible desde las herramientas de desarrollo del navegador “Google Chrome”. Con esta herramienta se obtuvieron los reportes de rendimiento, disponibles en el Anexo 03.

Con los resultados que se muestran en las imágenes anteriores se elaboró un histograma, tal y como se hizo con los dos objetivos anteriores, para analizar su distribución. Del gráfico se entendió que la mayor parte de las interfaces obtuvo entre 91 y 93 puntos y que sólo una interfaz logró obtener más de 94 puntos, esta fue la interfaz de autenticación que obtuvo exactamente 97 puntos. A continuación, se muestra el gráfico obtenido:



*Figura 10. Histograma de los resultados del tercer objetivo*

Para un análisis más preciso se mostrará en la siguiente tabla las medidas de tendencia central junto a la mínima y máxima puntuación obtenida:

*Tabla 10. Resumen de los resultados del tercer objetivo*

Medida	Valor
Media	92
Mediana	92
Moda	92
Mínimo	90
Máximo	97

## V. Discusión

Esta investigación fue planteada con el objetivo de implementar una solución de minería de datos que pronostique la demanda de medicamentos a partir de grandes volúmenes de datos y con un alto nivel de precisión en la farmacia de un establecimiento de salud, dado que durante el análisis de la situación se detectaron algunos aspectos en los que se podía innovar y, con ello afinar los resultados que genera este proceso, específicamente, se esperaba obtener la información necesaria para maximizar la demanda atendida y minimizar los costos de mantener medicamentos por mucho tiempo en el almacén. A continuación, se presentará la discusión enfocada en cada uno de los tres objetivos específicos que se tuvieron en este proyecto:

El primer objetivo específico de esta investigación tuvo como indicador el valor de R-cuadrado, sobre él se debe tener en consideración que su cálculo se ve influenciado de forma inversamente proporcional por la cantidad de datos que se usan como muestra, así, mientras menos observaciones se consideren el indicador tenderá más a la unidad, así mismo, se debe tener cuidado con la búsqueda de la maximización de este indicador ya que esto podría conducir a la aceptación de un modelo con el problema conocido como “Sesgo preprueba” que según Martínez [42] podría cambiar radicalmente las propiedades de los estimadores del modelo. Además, existen autores como Figueiredo, Silva y Rocha [43], que coinciden en afirmar que esta métrica presenta algunas limitaciones cuando se usa para seleccionar un modelo de pronóstico debido a que varía en función de la cantidad de predictores que se utilizan, es decir, sin importar si se están incluyendo variables explicativas no significativas, el valor de R-cuadrado seguirá aumentando, a este problema existen soluciones como R-cuadrado ajustado que penaliza la inclusión de nuevas variables o el R-cuadrado de predicción que trata de mostrar la bondad de un modelo para predecir datos no vistos durante el entrenamiento, sin embargo, estos problemas no desestiman la representación de esta métrica que debidamente complementada con otros datos, como el análisis de residuos, puede aportar

información relevante según el caso de estudio. Por lo mencionado, es comprensible que esta métrica no esté presente en las evaluaciones realizadas en los antecedentes de esta investigación y en consecuencia no se pueda realizar una comparación directa con los resultados aquí obtenidos. En cuanto al contexto de este proyecto, es oportuno destacar que con los experimentos realizados durante la construcción y evaluación de los modelos se obtuvo el fundamento necesario para respaldar las posturas mencionadas, en consecuencia, es necesario manifestar que el uso de R-cuadrado en esta investigación no correspondió al proceso de selección de modelos, sino que estuvo alineada a su naturaleza matemática de describir la varianza total de un modelo con respecto a la variable que trata de explicar. Con relación a los sesgos de esta métrica sobre la cantidad de predictores que se utilizan, se hace énfasis la naturaleza univariable del problema que se estudió y las precauciones tomadas en cuenta durante la medición como por ejemplo el seguimiento y análisis de la evolución de los modelos. Por otra parte, la no elección de alguna opción existente, como R-cuadrado ajustado o R-cuadrado de predicción, se justifica en la forma de aplicación de esta métrica, ya que la medición se realizó sobre el conjunto de datos de entrenamiento y en dicho caso se habría perdido el valor de R-cuadrado de predicción, de forma similar, el uso de R-cuadrado ajustado habría penalizado la inclusión de variables, que para este caso es particular, habría representado un sesgo adicional debido a que no todos los medicamentos presentan una serie temporal con la misma distribución de estacionalidad y en algunos casos fue necesaria la inclusión de más entradas en la red neuronal para interpretar correctamente el comportamiento de la demanda real.

El criterio de éxito fijado para este primer objetivo fue obtener un valor para R-cuadrado mayor a 0.6 en cada uno de los modelos que se construya, ello implicaría un nivel de “adaptación moderada” considerando la escala propuesta por Alhyari [44] donde esta categoría comprende los valores entre 0.5 y 0.7, igualmente cabía la posibilidad de que algunos de los modelos obtuvieran valores mayores para R-cuadrado y se ubiquen en el rango de valores de 0.7 a 1 que corresponde al nivel más alto de la misma escala denominado como “adaptación fuerte”. Tras el proceso de entrenamiento, evaluación y afinado, los modelos obtuvieron en promedio un valor de 0.9033 para la métrica R-cuadrado, por otro lado, dado que la mediana fue de 0.9995 se deduce que al menos el 50% de los modelos tuvieron un valor de casi 1, que en la interpretación de esta métrica implicaría que los modelos pueden describir perfectamente el comportamiento de la demanda real. Otro punto por resaltar es que el menor valor para R-cuadrado que se obtuvo fue de 0.6 mientras que el mayor valor obtenido fue de 1. Finalmente, por la precisión que tenían los valores de R-cuadrado era

difícil la identificación de una moda, por esto mismo, se decidió redondear los valores a 4 decimales obteniendo que la moda fue el valor de 0.9999.

El segundo objetivo específico utilizó MAPE como indicador ya que es una de las métricas más comunes en los problemas de pronóstico y al expresarse en forma de porcentaje es fácil de interpretar. Lo primero que se debe conocer sobre esta métrica es que cada caso de estudio podría presentar valores diferentes para MAPE y aun así ser igual de válidos siempre que se pueda demostrar la dificultad de pronóstico o que el conjunto de datos está generando anomalías en el cálculo. Además, se debe tener en cuenta que existen estudios como el de Calderón [15] donde se creó un modelo por cada uno de los siete productos que se estudiaron y para se obtuvo para tres de ellos que haciendo uso la técnica de regresión lineal se podía tener un MAPE de 8.3%, 8.7% y 15.6% respectivamente, para otros dos productos se obtuvo un MAPE de 10.7% y 26.5% utilizando la técnica de suavizado exponencial doble y para los dos últimos productos se utilizó la técnica de Promedio móvil y se obtuvo un MAPE de 23.3% y 12.8% respectivamente. Otra investigación interesante es la de Buissonneau, Mosquera y Gómez [14] donde se logró construir dos modelos que hacían uso de la técnica del promedio móvil ponderado y obtuvieron un MAPE de 22.3% y 20% respectivamente. En la investigación de Montenegro [18] se analizaron 4 medicamentos y para el pronóstico de la demanda de uno de ellos se utilizó el promedio móvil doble que obtuvo un MAPE de 15.19%, mientras que para otros tres medicamentos se utilizaron los modelos ARIMA que obtuvieron un MAPE de 11.13%, 8.24% y 9.17% respectivamente, así mismo, cabe mencionar la investigación de Leclerc [9] donde se analizaron 117 series de tiempo y para ejemplificarlo mostró el proceso de generación de pronósticos de un medicamento con el cual el menor MAPE fue de 40.04% y correspondía a la aplicación de un modelo ARIMA, por último, se destaca la investigación de Mamani [16] quien también a través del uso del esquema de modelos ARIMA logró generar pronósticos para una serie temporal de las ventas mensuales de productos de electro hogar con un 95% de confiabilidad. De las investigaciones mencionadas es relevante que en ellas se hace uso exclusivamente de técnicas estadísticas, de la misma forma, destaca que, en su mayoría, la cantidad de productos analizados es relativamente mínima debido a que cada modelo construido recibe un ajuste personalizado y manual por cada producto que se estudia, sin embargo, existen otras investigaciones en las cuales se hizo uso de técnicas del campo del Machine Learning con la finalidad de mejorar los resultados y automatizar el proceso de creación de los modelos de pronóstico facilitando su mantenimiento a través del tiempo, tal es el caso de la investigación de Molina [10] donde, para tres de los productos analizados, las redes neuronales obtuvieron el menor MAPE en

comparación con los modelos ARIMAX y Holt Winters, los valores de MAPE obtenidos por las redes neuronales fueron de 6.45%, 9.78% y 5.02%. Robles y Valverde [17] por su parte construyeron una red neuronal recurrente que tuvo un margen de error de entre el 15% y 40%. En el mismo sentido, Benites [19] utilizó una red neuronal para generar los pronósticos de venta de una empresa para un periodo de 7 meses con más del 90% de confiabilidad, mientras que Azañero y Ramírez [21] compararon una red neuronal con otras técnicas de pronóstico como los modelos ARIMA y el promedio móvil, obteniendo que la red neuronal tuvo el menor MAPE con un valor del 20%.

El criterio de éxito que se estableció para este segundo objetivo fue obtener valores menores a 40% para el MAPE de cada uno de los modelos que se construyan y así clasificarlos dentro la categoría “Pronóstico razonable” que comprende los valores entre 20% y 50% con la posibilidad de que algún modelo se clasifique dentro de las categorías “Pronóstico Bueno” o “Pronóstico excelente” que corresponden a los rangos de valores de 10% a 20% y menores a 10% respectivamente, todo esto según la escala propuesta por Lewis [46]. Los modelos construidos obtuvieron en promedio un MAPE del 17.8759% siendo que el valor más bajo que se obtuvo para MAPE fue del 5.07698% y el más alto fue del 39.9936%, la mediana fue 17.182% y la moda 14.4974%. En este punto cabe resaltar que MAPE representa el error de pronóstico y por ello mientras más bajo sea, mejor será el modelo.

El tercer objetivo específico propuesto en este proyecto planteó como indicador el puntaje que obtenga la aplicación web tras la evaluación de su rendimiento utilizando la herramienta “Lighthouse”, cabe resaltar que esta herramienta evalúa aspectos muy importantes del rendimiento como lo son el tiempo de la primera carga, índice de velocidad, tiempo de carga más grande, tiempo de interactividad, tiempo de bloqueo y los cambios en la disposición del contenido. La evaluación del rendimiento de una aplicación web es un tema importante cuando se plantean este tipo de soluciones ya que si no se tiene una forma fácil de acceder a los modelos de pronóstico estos quedarán fuera de la consideración del personal táctico de la organización. Existen antecedentes donde se le presta especial atención al rendimiento de la aplicación que se presentará como producto final, por ejemplo, en la investigación de Robles y Valverde [17] además de las pruebas funcionales se planificó la ejecución de pruebas de estrés para analizar el comportamiento del sistema web frente a un gran número de solicitudes simultáneas, exactamente, realizó 5 pruebas con 10, 20, 50, 100 y 200 usuarios concurrentes que generaban 100, 200, 500, 1000 y 2000 solicitudes respectivamente y obtuvo en cada una de ellas resultados positivos que le permitieron garantizar el correcto funcionamiento del sistema construido. Ante esto es preciso identificar la diferencia del enfoque de cada plan de

pruebas que se propone, ya que mientras para el antecedente es importante realizar pruebas de carga operativa debido a que el sistema construido soportará también los procesos logísticos de la empresa, para este proyecto tiene mayor prioridad la velocidad y usabilidad del sistema ya que el resto de los procesos se manejarán en el sistema actual de la empresa.

El criterio de éxito considerado en el tercer objetivo específico fue que el puntaje obtenido en la evaluación del rendimiento sea mayor o igual a 90 puntos, o lo que es lo mismo, obtenga la clasificación de “Bueno” según la escala propuesta por herramienta de medición de rendimiento ya mencionada. Tras la construcción de la aplicación y ejecución de la evaluación respectiva de todas las interfaces, el promedio, la mediana y la moda fueron 92 puntos, al mismo tiempo, la interfaz con el rendimiento más bajo obtuvo 90 puntos mientras que la interfaz con el mayor rendimiento fue calificada con 97 puntos, siendo justamente esta interfaz la única que sobrepasó el umbral de 94 puntos

## **VI. Conclusiones**

Teniendo en cuenta lo antes discutido y en general todo lo mencionado en este proyecto de investigación como producto del análisis de la literatura, estado del arte y conocimiento propio que fue generado durante la ejecución de las tareas propuestas, se concluye que:

Con el fin de demostrar la bondad de ajuste de cada modelo al comportamiento de la demanda, se realizaron los cálculos referentes a la métrica R-cuadrado teniendo en consideración las limitaciones de esta métrica y por ello tomando las medidas necesarias tales como el seguimiento a la evolución de los parámetros del modelo durante su entrenamiento para evitar sesgos en las interpretaciones y decisiones sobre la aceptación de modelos. Con esto, se demostró haber alcanzado un valor mayor a 0.6 en el nivel de adaptación del modelo de pronóstico a la demanda real de medicamentos, siendo el valor promedio obtenido 0.9.

Para asegurar la confianza y precisión de cada pronóstico generado se utilizó la métrica MAPE debido a su facilidad de interpretación al expresarse en forma de porcentaje, además, considerando los sesgos existentes en su cálculo, su uso fue evaluado durante el análisis y exploración de los conjuntos de datos donde se determinó que estos contaban con las características adecuadas para la aplicación de esta métrica, finalmente tras la medición sobre los modelos ya entrenados se afirma haber logrado un porcentaje menor a 40% en el error de precisión del pronóstico de la demanda de medicamentos dado que en promedio los modelos tuvieron un MAPE de 17.88%.

Buscando garantizar que los usuarios puedan interactuar en cualquier momento con los modelos de pronóstico de la demanda y perciban siempre un buen rendimiento, se evaluó cada interfaz construida en función del tiempo de la primera carga, índice de velocidad, tiempo de carga más grande, tiempo de interactividad, tiempo de bloqueo y cambios en la disposición del contenido, todo ello utilizando la herramienta Lighthouse debido a su fiabilidad. Tras la ejecución de la medición se obtuvo en promedio una calificación de 92 puntos, evidenciando así, haber obtenido una puntuación mayor al 90% en la evaluación del rendimiento de la aplicación web utilizando la herramienta de medición de rendimiento.

## **VII. Recomendaciones**

En base a la ejecución de esta investigación y reconociendo la necesidad e importancia de la mejora continua junto con los beneficios de desarrollar este tipo de soluciones, se recomienda:

Analizar las nuevas técnicas del Machine Learning u otras ciencias que puedan adaptarse para el pronóstico de series temporales con el fin de comparar los resultados obtenidos y que cada empresa pueda adoptar la solución que mejor se adecue a sus necesidades.

Considerar los nuevos avances en infraestructura tecnológica para determinar la posibilidad de obtener mejoras en el rendimiento a gran escala o reducir los costos de adopción e implementación en los diferentes tipos de empresas interesadas.

Evaluar nuevos conjuntos de datos contextualizados a las futuras investigaciones que permitan añadir variables significativas a los modelos de pronóstico a fin de valorar la relevancia de las diferencias que se obtengan en la precisión y en la tolerancia a los cambios del mercado.

Analizar y adaptar la presente solución a productos de otros sectores donde existan series temporales con las mismas o diferentes características estacionarias en el comportamiento de su demanda para comparar la bondad de los modelos ante estas nuevas situaciones.



## VIII. Referencias

- [1] Comisión Económica para América Latina y el Caribe (CEPAL), «Tecnologías digitales para un nuevo futuro,» Santiago, 2021.
- [2] A. Gray y H. R. Manasse, «Escasez de medicamentos: un problema mundial complejo,» *Boletín de la Organización Mundial de la Salud*, n° 90, p. 158, 2012.
- [3] Organización Mundial de la salud, «La escasez mundial de medicamentos y vacunas y el acceso a ellos,» Asamblea Mundial de la Salud, 2017.
- [4] E. Menasalvas, C. Gonzalo y A. Rodríguez, «Big data en salud: Retos y Oportunidades,» Madrid, 2017.
- [5] P. Copa Castellano y B. Mejuto Pérez del Molino, «Desabastecimiento de medicamentos: un problema en constante crecimiento,» *Pharmaceutical care*, vol. 22, n° 4, pp. 207-223, 2020.
- [6] El comercio, «ComexPerú: precios altos de medicamentos “reflejan un problema de desabastecimiento”,» 19 Mayo 2020. [En línea]. Available: <https://n9.cl/wskde>. [Último acceso: 10 04 2021].
- [7] Datasur, «El problema en la previsión del sector salud: El desabastecimiento de medicamentos en el Perú,» 25 Septiembre 2019. [En línea]. Available: <https://n9.cl/p5y7>. [Último acceso: 15 Mayo 2021].
- [8] Jefa de ventas y almacén, *Entrevista para comprender la problemática*, Chiclayo, 2021.
- [9] D. G. Leclerc Correa, *Desarrollo de un modelo de estimación de demanda de medicamentos para una empresa farmacéutica*, Santiago de Chile: Universidad de Chile, 2020.
- [10] K. G. Molina Rea, *Implementación de un modelo analítico para la predicción de la venta del portafolio de productos OTC de un laboratorio farmacéutico*, Quito: Universidad de las Fuerzas Armadas ESPE. Maestría en Gestión de Sistemas de Información e Inteligencia de Negocios, 2020.
- [11] S. Gregor y A. Hevner, «The Knowledge Innovation Matrix (KIM): A clarifying lens for innovation,» *Informing Science: the International Journal of an Emerging Transdiscipline*, vol. 17, pp. 217-239, 2014.
- [12] J. Lozada, «Investigación Aplicada: Definición, propiedad intelectual e Industria,» *CienciAmérica: Revista de divulgación científica de la Universidad Tecnológica Indoamérica*, vol. III, n° 1, pp. 47-50, 2014.

- [13] H. White y S. Sabarwal, «Diseño y métodos cuasiexperimentales,» Centro de Investigaciones de UNICEF, Florencia, 2014.
- [14] E. Buissonneau, J. J. Gómez Rueda y J. C. Mosquera Valenzuela, *Pronóstico de demanda para la empresa El Parisino S.A.S.*, Pereira: Universidad Católica de Pereira, 2021.
- [15] M. P. Calderón Pazce, *Proyecto de mejora del sistema de pronósticos de la categoría lavavajillas en una empresa de consumo masivo.*, Lima: Pontificia Universidad Católica del Perú, 2021.
- [16] B. Mamani Mamani, *Modelo de pronóstico univariante de ventas mensuales de productos de la división de Electrohogar en Tiendas Peruanas S.A. Oechsle Huancayo 2009 – 2017*, Puno: Universidad Nacional del Altiplano, 2019.
- [17] M. A. Robles Rakov y M. Y. Valverde Campos, *Sistema de predicción para incrementar las ventas de accesorios y repuestos automotrices en la empresa GGP Automotriz*, Lima: Universidad de San Martín de Porres, 2021.
- [18] C. L. A. Montenegro Morales, *Evaluación de métodos de pronósticos para predecir las ventas de los productos de la línea cardiológica de la Botica San Carlos*, Chiclayo: Universidad Católica Santo Toribio de Mogrovejo, 2019.
- [19] J. M. Benites Sernaqué, *Implementación de un sistema de pronóstico de ventas utilizando redes neuronales artificiales para la empresa Cerámicos Lambayeque SAC*, Pimentel: Universidad Señor de Sipán, 2021.
- [20] I. Kaastra y M. Boyd, «Designing a neural network for forecasting financial and economic time series,» *Neurocomputing*, vol. 10, n° 3, pp. 215-236, 1996.
- [21] J. A. Azañero Burga y R. J. Ramirez Sipion, *Análisis comparativo de algoritmos de pronóstico de ventas para su implementación en mypes del sector ferretería de Chiclayo*, Pimentel: Universidad Señor de Sipán, 2019.
- [22] E. G. Aguilar Riera y D. A. Dávila Garzón, *Análisis, diseño e implementación de la aplicación web para el manejo del distributivo de la facultad de ingeniería*, Cuenca: Universidad de Cuenca, 2013.
- [23] MongoDB, «¿Qué es MongoDB?,» 2020. [En línea]. Available: <https://www.mongodb.com/what-is-mongodb>. [Último acceso: 5 11 2020].
- [24] PostgreSQL, «PostgreSQL: The World's Most Advanced Open Source Relational Database,» 2021. [En línea]. Available: <https://www.postgresql.org/>. [Último acceso: 07 01 2021].

- [25] Nodejs, «Nodejs: Documentación,» 2020. [En línea]. Available: <https://nodejs.org/es/docs/>. [Último acceso: 8 10 2020].
- [26] PHP, «¿Qué es PHP?,» 2020. [En línea]. Available: <https://www.php.net/manual/es/intro-what-is.php>. [Último acceso: 20 11 2020].
- [27] Flask, «Foreword,» 2010. [En línea]. Available: <https://flask.palletsprojects.com/en/2.1.x/foreword/>. [Último acceso: 03 05 2021].
- [28] A. Soto Bueno, «Diferencia entre arquitectura monolítica y de microservicios,» openwebinars, 12 Noviembre 2018. [En línea]. Available: <https://n9.cl/lj5m2>. [Último acceso: 10 05 2021].
- [29] kapilparshi, «Difference between Shared Nothing Architecture and Shared Disk Architecture,» 20 Mayo 2020. [En línea]. Available: <https://www.geeksforgeeks.org/difference-between-shared-nothing-architecture-and-shared-disk-architecture/>. [Último acceso: 11 06 2021].
- [30] Red Hat, «¿Qué es una arquitectura de aplicaciones?,» 09 Marzo 2020. [En línea]. Available: <https://www.redhat.com/es/topics/cloud-native-apps/what-is-an-application-architecture>. [Último acceso: 10 06 2021].
- [31] Y. Belinchón Monjas, *Minería de datos*, Madrid: Universidad Carlos III de Madrid.
- [32] J. J. Montaña Moreno, *Redes Neuronales Artificiales aplicadas al análisis de datos*, Palma de Mallorca: Universitat de les Illes Balears, 2002.
- [33] A. Morera Munt, *Introducción a los modelos de redes neuronales artificiales El Perceptrón simple y multicapa*, Zaragoza: Universidad de Zaragoza, 2018.
- [34] I. E. Cicero, *Utilización de redes neuronales convolucionales para la detección de tipos de imágenes*, Buenos Aires: Instituto tecnológico de Buenos Aires, 2018.
- [35] N. Chávez Quisbert, «Modelos ARIMA,» *Revista Ciencia y Cultura*, nº 1, pp. 23-30, 1997.
- [36] S. De la Fuente Fernández, *Series temporales: Modelo ARIMA*, Madrid: Universidad Autónoma de Madrid.
- [37] IBM, «Criterios ARIMA de series temporales,» 17 Agosto 2021. [En línea]. Available: <https://n9.cl/5b2h>. [Último acceso: 18 Abril 2022].
- [38] M. J. Alarcón, «Clasificación del método de pronóstico de Torres,» *Poliantea*, vol. 5, nº 9, 2009.
- [39] Mohamad, «MSE – Error Cuadrático Medio,» 09 Marzo 2017. [En línea]. Available:

- <https://n9.cl/a8rt>. [Último acceso: 14 09 2021].
- [40] Mohamad, «MAE - Error medio absoluto,» 26 Octubre 2016. [En línea]. Available: <https://n9.cl/024k3>. [Último acceso: 14 Septiembre 2021].
- [41] J. F. López, «Ecomipedia,» 02 Octubre 2017. [En línea]. Available: <https://n9.cl/nky3>. [Último acceso: 06 09 2021].
- [42] E. Martínez Rodríguez, «Errores frecuentes en la interpretación del coeficiente de determinación lineal,» *Anuario Jurpdico y Económico Escorialense*, vol. XXXVIII, pp. 315-332, 2005.
- [43] D. Figueiredo, S. Júnior y E. Rocha, «What is R2 all about?,» *Leviathan-Cadernos de Pesquisa Polútica*, vol. 3, pp. 60-68, 2011.
- [44] S. Alhyari, «Re: What is the acceptable R-squared in the information system research? Can you provide some references?,» 18 Enero 2016. [En línea]. Available: <https://n9.cl/ostacc>. [Último acceso: 07 Septiembre 2021].
- [45] D. F. Betancourt, «Medición del error en pronósticos de demanda,» 07 Marzo 2016. [En línea]. Available: <https://n9.cl/i537>. [Último acceso: 07 Septiembre 2021].
- [46] C. D. Lewis, *Industrial and business forecasting methods : a practical guide to exponential smoothing and curve fitting*, London: Butterworth Scientific, 1982.
- [47] A. M. Coca Carasila, «La demanda. Una perspectiva de marketing: reflexiones conceptuales y aplicaciones,» *Perspectivas*, n° 28, pp. 171-191, 2011.
- [48] N. G. Mankiw, «Las fuerzas del mercado de la oferta y la demanda,» de *Principios de Economía*, pp. 65-131.
- [49] M. Gómez Puig, *Introducción a la microeconomía*, Barcelona: Universitat de Barcelona, 2006.
- [50] D. L. Saldarriaga R, «Pronóstico de la demanda,» *Zona Logística*, pp. 27-31.
- [51] T. Gálvez, «¿Cómo medir la precisión de los pronósticos?,» LinkedIn, 09 Agosto 2016. [En línea]. Available: <https://n9.cl/cypdn>. [Último acceso: 08 Septiembre 2021].
- [52] E. Lewinson, «Choosing the correct error metric: MAPE vs. sMAPE,» Towards data science, 01 Noviembre 2020. [En línea]. Available: <https://n9.cl/fgenj>. [Último acceso: 09 Septiembre 2021].
- [53] M. Abramowitz y I. Stegun, *Handbook of Mathematical Functions With: Formulas, Graphs, and Mathematical Tables.*, New York: Dover Publications, 1965.

## IX. Anexos

### *Anexo N° 01: Ficha de observación*

<b>Proceso:</b> Ejecución de venta			
<b>Fecha</b>	25/06/21	<b>Lugar</b>	Farmacia del establecimiento de salud.
<b>Propósito</b>	Conocer el proceso principal de la farmacia para establecer supuestos sobre la confiabilidad e integridad de los datos con los que se trabajará, así mismo identificar oportunidades de integración del futuro sistema para que la nueva solución obtenga datos en tiempo real.		
<b>Observaciones</b>			
<p>Uno de los activos principales para la atención de una venta en la farmacia es el sistema de información con el que cuentan, este es administrado por un tercero y en él se puede consultar la disponibilidad de un medicamento y el precio del mismo, posterior a estas consultas el medicamento es buscado en los estantes, vitrinas o almacén dependiendo del criterio de organización interno que se tiene establecido en la empresa y que el personal conoce muy bien.</p> <p>En el momento en que la venta es confirmada por ambas partes, esta es registrada en el sistema indicando la fecha, medicamento, cantidad y el monto, por otro lado, todos los registros corresponden a un cliente genérico.</p>			
<b>Interpretaciones</b>			
<p>Con lo observado se plantean los siguientes supuestos para su posterior análisis:</p> <ul style="list-style-type: none"> <li>• Los datos representan fielmente las ventas concretadas en la farmacia.</li> <li>• Se espera un alto nivel de limpieza y estandarización de los datos dado que el sistema informático que se usa cuenta con las validaciones mínimamente necesarias.</li> </ul>			

**Anexo N° 02: Registro de requisitos**

<b>Especificación de requisitos</b>							
<b>Proyecto</b> Sistema web de pronóstico de demanda					<b>Fecha</b> 25 / 06 / 2021		
<b>ID</b>	<b>Historia de usuario</b>	<b>Requisito</b>	<b>Módulo</b>	<b>Estado</b>	<b>Dimensión / Esfuerzo</b>	<b>Sprint</b>	<b>Comentarios</b>
<b>H-01</b>	Como administrador necesito establecer que usuarios pueden o no entrar al sistema para proteger la información	Registro.	Seguridad	Pendiente	4SP	Sprint #1	-
		Inicio de sesión.					
		CRUD de usuarios.					
<b>H-02</b>	Como administrador necesito controlar a que información accede cada usuario según su cargo para mantener la privacidad de la información confidencial.	Administración de roles.	Seguridad	Pendiente	2SP	Sprint #1	-
		Asignación de roles a los usuarios.					
<b>H-03</b>	Como administrador necesito actualizar los pronósticos de la demanda cada 6 meses para mejorar la precisión	Administración de modelos (Creación, reentrenamiento, modificación de parámetros y eliminación.)	Pronóstico de la demanda	Pendiente	3SP	Sprint #2	-
<b>H-04</b>	Como jefe de ventas necesito ver el comportamiento de la demanda de cada medicamento	Generar reportes del comportamiento real de la demanda.	Reportes	Pendiente	1SP	Sprint #2	-




<b>H-05</b>	Como jefe de ventas necesito ver resúmenes de los medicamentos más vendidos, los menos vendidos para tomar decisiones sobre el abastecimiento.	Generar reportes resumidos sobre la demanda de los medicamentos.	Reportes	Pendiente	2SP	Sprint #2	-
<b>H-06</b>	Como jefe de ventas necesito ver cómo se comportará la demanda de cada medicamento a futuro para prever estrategias.	Generar reportes de las proyecciones de los medicamentos.	Reportes	Pendiente	1SP	Sprint #3	-
<b>H-07</b>	Como jefe de ventas necesito saber qué medicamentos necesito comprar y en qué cantidad para abastecer el almacén correctamente.	Generar reportes de necesidad de abastecimiento (En base al stock evaluar si se necesita comprar o con las existencias será suficiente para cubrir la demanda)	Reportes	Pendiente	3SP	Sprint #3	-

### Observaciones

De la construcción y prueba de los modelos se concluyó que será necesario adicionar al sistema funcionalidades que permitan manejar los procesos asíncronos de entrenamiento de los modelos y generación de pronósticos además de incluir en el sistema la posibilidad de escalar los pronósticos para acercarlos al comportamiento real en casos de cambios súbitos e imposibles de predecir en el mercado.

### Anexo N° 03: Reportes de evaluación de rendimiento

30/11/21 15:55 Lighthouse Report Viewer

 http://localhost:3000/login  

## Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

▲ 0-49 ■ 50-89 ● 90-100

#### METRICS

[Expand view](#)

First Contentful Paint <b>0.7 s</b>	Speed Index <b>0.7 s</b>
Largest Contentful Paint <b>1.2 s</b>	Time to Interactive <b>0.7 s</b>
Total Blocking Time <b>0 ms</b>	Cumulative Layout Shift <b>0</b>

[View Treemap](#)

Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
Enable text compression	<b>0.4 s</b>
Reduce unused JavaScript	<b>0.24 s</b>
Reduce unused CSS	<b>0.16 s</b>

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

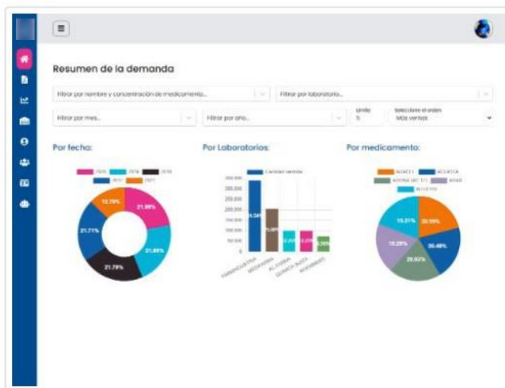




### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Speed Index  
**1.4 s**

■ Largest Contentful Paint  
**1.7 s**

● Time to Interactive  
**1.1 s**

● Total Blocking Time  
**0 ms**

● Cumulative Layout Shift  
**0.001**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
<span style="color: orange;">■</span> Enable text compression	<span style="width: 100px; height: 10px; background-color: orange; display: inline-block;"></span> 0.68 s <span style="float: right;">▼</span>
<span style="color: orange;">■</span> Reduce unused JavaScript	<span style="width: 100px; height: 10px; background-color: orange; display: inline-block;"></span> 0.28 s <span style="float: right;">▼</span>

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

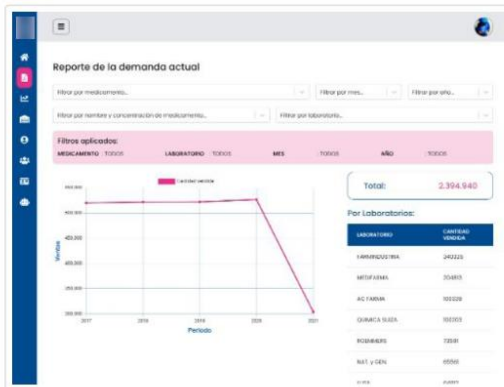
#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



### METRICS

[Expand view](#)

■ First Contentful Paint

**1.0 s**

■ Largest Contentful Paint

**1.7 s**

● Total Blocking Time

**10 ms**

● Speed Index

**1.2 s**

● Time to Interactive

**1.6 s**

● Cumulative Layout Shift

**0.034**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

### OPPORTUNITIES

Opportunity

Estimated Savings

■ Enable text compression

**0.64 s** ▼

■ Reduce unused JavaScript

**0.32 s** ▼

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

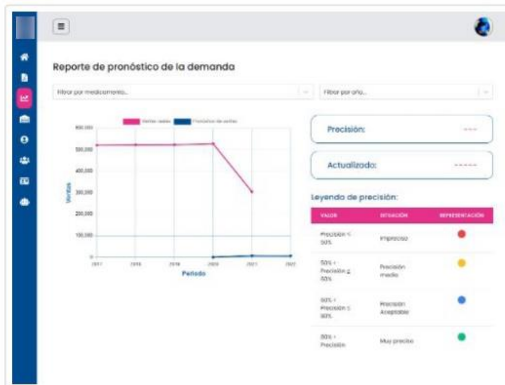
### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

● Speed Index  
**1.1 s**

■ Largest Contentful Paint  
**1.6 s**

● Time to Interactive  
**1.6 s**

● Total Blocking Time  
**50 ms**

● Cumulative Layout Shift  
**0.054**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	<span style="width: 100px; height: 10px; background-color: orange; display: inline-block;"></span> 0.64 s ▾
■ Reduce unused JavaScript	<span style="width: 100px; height: 10px; background-color: orange; display: inline-block;"></span> 0.32 s ▾

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

▲ 0–49   ■ 50–89   ● 90–100

DESCRIPCION	PRECEDENCIA	SERVICIO	DETALLE
A FUSO (50 mg) - C/ANIMA	83.75 %	517	
AN AMBROXOL (500 mg) - FARMACIA/UTIMA	83.75 %	385	
ACQUASALAMINA (200 mg) - FARMACIA/UTIMA	84.87 %	282	
ADICIONE (200 mg) - FARMACIA/UTIMA	78.76 %	468	
ADICIONE (200 mg) - FARMACIA/UTIMA	84.38 %	516	
ADACTE (500 mg) - SANOFI	95.45 %	64	
ALDO (200 mg) - SANOFI (50 mg) - C/ANIMA	88.28 %	539	

### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**1.6 s**

● Total Blocking Time  
**10 ms**

● Speed Index  
**1.0 s**

● Time to Interactive  
**1.9 s**

● Cumulative Layout Shift  
**0.015**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.4 s
■ Reduce unused JavaScript	0.2 s
■ Reduce unused CSS	0.16 s


These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0-49
- 50-89
- 90-100



#### METRICS

[Expand view](#)

● First Contentful Paint

0.9 s

■ Largest Contentful Paint

1.7 s

● Total Blocking Time

0 ms

● Speed Index

1.0 s

● Time to Interactive

1.1 s

● Cumulative Layout Shift

0.003

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.4 s
■ Reduce unused CSS	0.16 s
■ Reduce unused JavaScript	0.16 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

-  0-49
-  50-89
-  90-100



#### METRICS

[Expand view](#)

 First Contentful Paint

0.9 s

 Largest Contentful Paint


1.9 s

 Total Blocking Time

0 ms

 Speed Index

1.0 s

 Time to Interactive

1.2 s

 Cumulative Layout Shift

0.003

[View Treemap](#)




Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)


#### OPPORTUNITIES



Opportunity

Estimated Savings

 Enable text compression

 0.53 s 

 Reduce unused JavaScript

 0.29 s 

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

▲ 0–49    ■ 50–89    ● 90–100

A screenshot of a web application interface titled 'Usuarios'. It shows a table with columns for 'APLICACION Y PASSWORD', 'NOMBRE DE USU', 'ESTADO', and 'ACCIONES'. The table contains five rows of user data.

APLICACION Y PASSWORD	NOMBRE DE USU	ESTADO	ACCIONES
PERFIL_MARIA maria@perfiles.com	30000000	Activo	🔍 🗑️ 🔄
PERFIL_VIKTOR viktor@perfiles.com	0545678	Activo	🔍 🗑️ 🔄
PERFIL_BIL bil@perfiles.com	0245678	Activo	🔍 🗑️ 🔄
PERFIL_MARCO marco@perfiles.com	0545678	Activo	🔍 🗑️ 🔄
PERFIL_JUAN juan@perfiles.com	88888888	Activo	🔍 🗑️ 🔄

### METRICS

[Expand view](#)

● First Contentful Paint  
**0.7 s**

■ Largest Contentful Paint  
**1.8 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**0.9 s**

● Time to Interactive  
**1.3 s**

● Cumulative Layout Shift  
**0.005**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.5 s
■ Reduce unused JavaScript	0.26 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

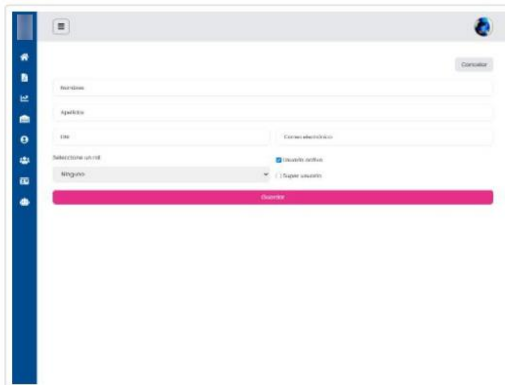
### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**1.7 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**1.2 s**

● Time to Interactive  
**1.2 s**

● Cumulative Layout Shift  
**0.003**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.37 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

#### DIAGNOSTICS

- User Timing marks and measures — 4 user timings

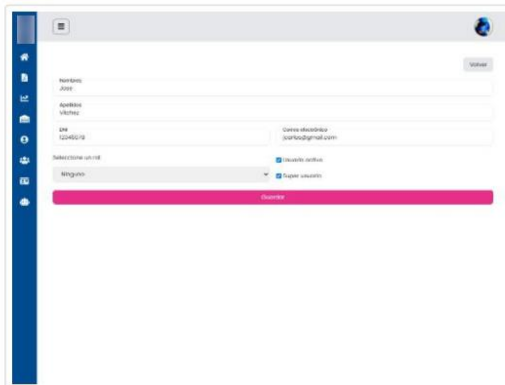




### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint

0.9 s

■ Largest Contentful Paint

1.7 s

● Total Blocking Time

0 ms

● Speed Index

1.0 s

● Time to Interactive

1.2 s

● Cumulative Layout Shift

0.001

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity

Estimated Savings

■ Enable text compression

0.56 s

■ Reduce unused JavaScript

0.24 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

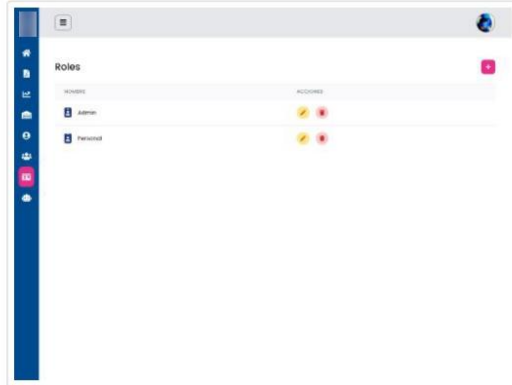
#### DIAGNOSTICS



### Performance


Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

-  0-49
-  50-89
-  90-100



#### METRICS


[Expand view](#)


 First Contentful Paint  
**0.9 s**

 Largest Contentful Paint  
**1.7 s**

 Total Blocking Time  
**20 ms**

 Speed Index  
**1.0 s**

 Time to Interactive  
**1.3 s**





 Cumulative Layout Shift  
**0**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
 Enable text compression	 0.48 s 
 Reduce unused JavaScript	 0.24 s 

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

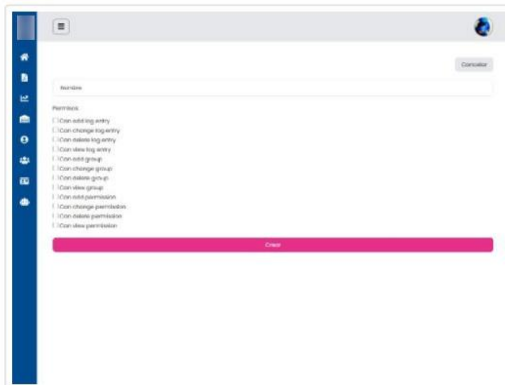
#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.6 s**

■ Largest Contentful Paint  
**2.0 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**1.0 s**

● Time to Interactive  
**1.2 s**

● Cumulative Layout Shift  
**0.022**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.4 s
■ Reduce unused JavaScript	0.2 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

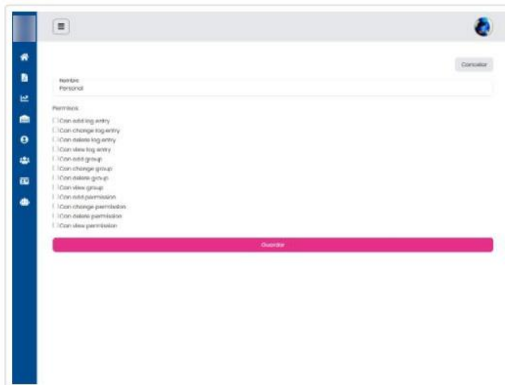
#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**2.0 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**1.0 s**

● Time to Interactive  
**1.2 s**

● Cumulative Layout Shift  
**0.019**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity

Estimated Savings

■ Enable text compression

■ 0.36 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

#### DIAGNOSTICS

User Timing marks and measures — 7 user timings



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100

Modelo	Fecha de ejecución	% de Precisión	Estado	Acciones
A POC (3 s mg)	30/11/2021 12:35:08	92.6 %	Usando	
AS AMBROSIA (260 mg)	30/11/2021 12:35:41	64.30 %	Enviado	
AS AMBROSIA (220 mg)	30/11/2021 12:35:42	61.94 %	Enviado	

### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**1.7 s**

● Total Blocking Time  
**10 ms**

● Speed Index  
**1.3 s**

● Time to Interactive  
**2.0 s**

● Cumulative Layout Shift  
**0.003**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.7 s
■ Reduce unused JavaScript	0.32 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

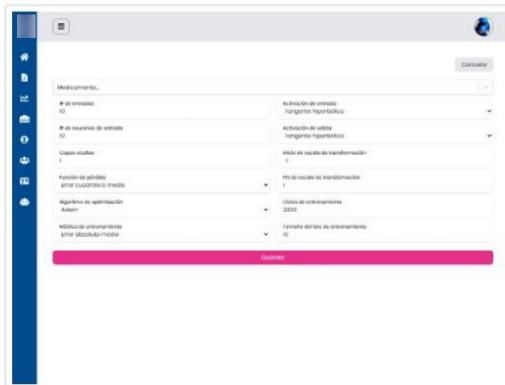
### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**1.9 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**1.0 s**

● Time to Interactive  
**1.1 s**

● Cumulative Layout Shift  
**0.003**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.6 s
■ Reduce unused JavaScript	0.24 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

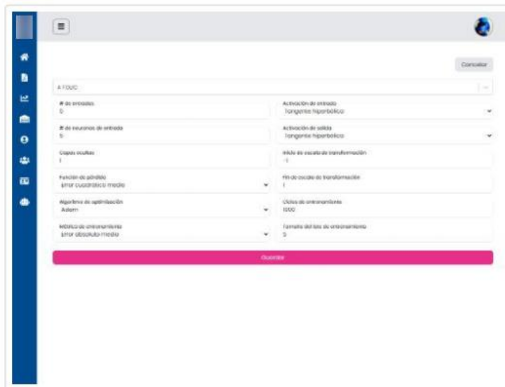
#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

- ▲ 0–49
- 50–89
- 90–100



#### METRICS

[Expand view](#)

● First Contentful Paint  
**0.9 s**

■ Largest Contentful Paint  
**2.0 s**

● Total Blocking Time  
**0 ms**

● Speed Index  
**1.0 s**

● Time to Interactive  
**1.1 s**

● Cumulative Layout Shift  
**0**

[View Treemap](#)



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

#### OPPORTUNITIES

Opportunity	Estimated Savings
■ Enable text compression	0.52 s
■ Reduce unused JavaScript	0.2 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

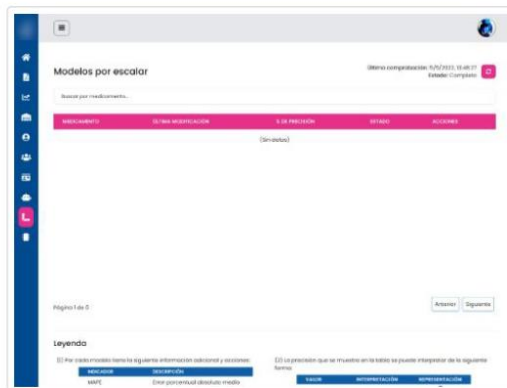
#### DIAGNOSTICS



### Performance

Values are estimated and may vary. The performance score is calculated directly from these metrics. See calculator.

- 0-49
- 50-89
- 90-100



#### METRICS

Expand view

● First Contentful Paint  
0.9 s

● Speed Index  
1.2 s

■ Largest Contentful Paint  
1.9 s

● Time to Interactive  
1.3 s

● Total Blocking Time  
0 ms

● Cumulative Layout Shift  
0.032

[View Treemap](#)



Show audits relevant to: **All** FCP TBT LCP CLS

#### OPPORTUNITIES

Opportunity

Estimated Savings

■ Reduce unused JavaScript

0.28 s

These suggestions can help your page load faster. They don't directly affect the Performance score.

#### DIAGNOSTICS

○ User Timing marks and measures — 4 user timings

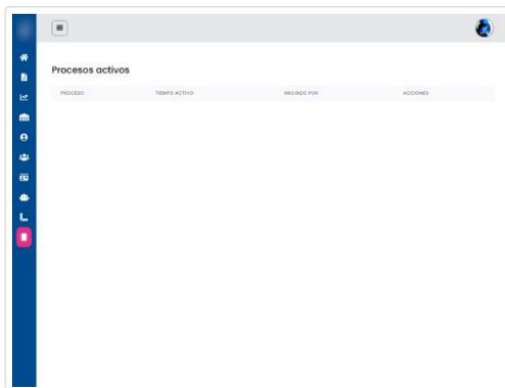




### Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

-  0–49
-  50–89
-  90–100



#### METRICS

[Expand view](#)

 First Contentful Paint

0.9 s

 Speed Index

1.0 s

 Largest Contentful Paint

1.5 s

 Time to Interactive

1.2 s

 Total Blocking Time

0 ms

 Cumulative Layout Shift

0.003

[View Treemap](#)




Show audits relevant to: [All](#) [FCP](#) [TBT](#) [LCP](#) [CLS](#)

#### OPPORTUNITIES

Opportunity

Estimated Savings

 Reduce unused JavaScript

 0.2 s

These suggestions can help your page load faster. They don't [directly affect](#) the Performance score.

#### DIAGNOSTICS

User Timing marks and measures — 4 user timings