

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Electricidad y Computación

Desarrollo de un sistema predictivo de ventas para la industria farmacéutica

TECH-377

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Ciencias de la Computación

Presentado por:

Jean Frank Villamar Lindao

Johnny Enrique Cotrina Oquendo

Guayaquil - Ecuador

Año: 2024

Dedicatoria

El presente proyecto lo dedico a mi familia, por su constante apoyo y comprensión en cada etapa de este camino. A todas las personas que han sido partícipe de esta etapa de mi vida.

Johnny Enrique Cotrina Oquendo

El presente proyecto lo dedico a mi familia, cuya constante motivación y apoyo han sido esenciales en cada paso de este camino. Agradezco también a todos aquellos que han contribuido de alguna manera en este significativo proceso.

Jean Frank Villamar Lindao

Agradecimientos

Mi más sincero agradecimiento a mis padres, el Lcdo. John Cotrina y la Lcda. Silvia Oquendo, quienes han sido el soporte clave en mi camino hacia este logro. El constante apoyo de mi madre ha sido mi inspiración para alcanzar mis metas. A mi hermana, la Ing. Gianella Rizzo, por ser un ejemplo para mi vida. A los excelentes docentes y al personal de ESPOL, en especial a E. Cruz y M. Realpe. Además, quiero agradecer a mis amigos: Génesis, Mayli, John, Jean y Andrés, por acompañarme siempre en cada etapa de mi vida académica.

Johnny Enrique Cotrina Oquendo

Mi más sincero agradecimiento a mi familia,
mis docentes y mis amistades por haber
formado parte de este tramo tan importante de
mi vida.

Jean Frank Villamar Lindao

Declaración Expresa

Yo/Nosotros Johnny Enrique Cotrina Oquendo y Jean Frank Villamar Lindao acuerdo/acordamos y reconozco/reconocemos que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí/nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me/nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi/nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al/los autor/es que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 27 de septiembre del 2024.



Firmado digitalmente por:
JOHNNY ENRIQUE
COTRINA OQUENDO

Johnny Enrique Cotrina
Oquendo

Jean Frank Villamar

Lindao

Evaluadores

Boris Vintimilla Burgos

Profesor de Materia

Miguel Realpe Robalino

Tutor de proyecto

Resumen

El proyecto aborda la problemática de la variabilidad en la demanda y la gestión de productos con fecha de vencimiento en una distribuidora farmacéutica. El objetivo es desarrollar un sistema predictivo utilizando inteligencia artificial para mejorar la precisión en las estimaciones de ventas y minimizar pérdidas económicas. Se justificó la necesidad de este sistema debido a las limitaciones de los métodos tradicionales y su impacto negativo en la eficiencia operativa. Para el desarrollo del proyecto, se utilizó una red neuronal LSTM, integrada en una arquitectura basada en servicios de AWS. Se recopilaron datos históricos de ventas, los cuales fueron procesados para entrenar el modelo predictivo. Los resultados demostraron que el modelo alcanzó una precisión adecuada en las predicciones, permitiendo optimizar la gestión de inventarios y reducir el desperdicio de productos. En conclusión, el sistema desarrollado ofrece una solución efectiva para la gestión de inventarios, garantizando una mejor toma de decisiones y sostenibilidad operativa.

Palabras Clave: Predicción de ventas, dashboard, red neuronal, gestión de inventario

Abstract

The project addresses the problem of variability in demand and management of products with expiration dates in a pharmaceutical distributor. The objective is to develop a predictive system using artificial intelligence to improve the accuracy of sales estimates and minimize economic losses. The need for this system was justified due to the limitations of traditional methods and their negative impact on operational efficiency. For the development of the project, an LSTM neural network was used, integrated into an architecture based on AWS services. Historical sales data was collected, which was processed to train the predictive model. The results showed that the model achieved adequate accuracy in predictions, allowing to optimize inventory management and reduce product waste. In conclusion, the developed system offers an effective solution for inventory management, ensuring better decision making and operational sustainability.

Keywords: *Sales forecasting, dashboard, neural network, inventory management*

Índice general

Resumen	8
Abstract	9
Índice general	10
Abreviaturas	12
Índice de figuras	13
Índice de tablas.....	15
Capítulo 1	16
1.1 Introducción	17
1.2 Descripción del Problema	18
1.3 Justificación del Problema	19
1.4 Objetivos	19
1.4.1 Objetivo general	19
1.4.2 Objetivos específicos.....	20
1.5 Marco teórico	20
1.5.1 Gestión de Inventario de la Industria Farmacéutica	21
1.5.2 Demanda y variabilidad en el Sector Farmacéutico	21
1.5.3 Tecnologías de análisis predictivo.....	23
1.5.4 Herramientas de visualización.....	24
1.5.5 Infraestructura en la nube	25
1.5.6 Impacto del análisis predictivo en la toma de decisiones.....	27
Capítulo 2	28
2. Metodología.	29
2.1 Plan de recolección de datos	29
2.2 Fiabilidad de datos	29
2.3 Análisis exploratorio de datos.....	30
2.4 Propuesta de solución	32

Capítulo 3	38
3. Resultados y análisis	39
3.1 Toma de requerimientos	39
3.1.1 Requerimientos funcionales	39
3.1.2 Requerimientos no funcionales	40
3.2 Implementación de prototipo	40
3.3 Implementación de la solución	41
3.3.1 Implementación de modelo LSTM.....	42
3.3.2 Implementación del dashboard.....	52
3.3.3 Implementación de arquitectura en AWS.....	53
3.4 Resultados.....	55
3.4.1 Rendimiento del modelo.....	55
3.4.2 Visualización interfaz gráfica.....	64
3.4.3 Pruebas de validación.....	67
Capítulo 4	71
4.1 Conclusiones y recomendaciones.....	72
4.1.1 Conclusiones.....	72
4.1.2 Recomendaciones	72
Referencias	74

Abreviaturas

AWS	Amazon Web Services
CMD	Command Prompt
ESPOL	Escuela Superior Politécnica del Litoral
GCP	Google Cloud Platform
IA	Inteligencia Artificial
LSTM	Long short-term memory
ML	Machine Learning
RFID	Identificación por radiofrecuencia
RNN	Redes Neuronales Recurrentes
RMSE	Error cuadrático medio

Índice de figuras

Figura 1. Top 20 productos que generan pérdidas a la empresa organizados por cantidad de caducados	30
Figura 2. Top 20 productos que generan mayores pérdidas para la empresa por motivos de caducidad organizados por valor total de pérdida	31
Figura 3. Arquitectura propuesta de solución	36
Figura 4. Diagrama de actividades	37
Figura 5. Vista del Dashboard – Prototipo	41
Figura 6. Gráfico año v.s cantidad idItem=88275	44
Figura 7. Espectro de frecuencias idItem=88275	45
Figura 8. Dificultades al utilizar variables temporales [33]	46
Figura 9. Gráfica Senoidal de Datos Mensuales a lo Largo del Tiempo	47
Figura 10. Gráfica Senoidal y Cosenoidal de Datos Mensuales a lo Largo del Tiempo	47
Figura 11. Dataframe con los valores codificados	48
Figura 12. Gráfico de violín de los features del modelo escalados	48
Figura 13. Entrada y salida del modelo	49
Figura 14. Proceso de predicción de cantidades vendidas con LSTM	50
Figura 15. Diagrama del proceso de predicción multi-step recursivo, para predecir 3 steps a futuro utilizando los últimos 4 lags de la serie como predictores [34]	51
Figura 16. Arquitectura de Integración de AWS Lambda con S3 y CloudWatch	53
Figura 17. Levantamiento de instancia en EC2	54
Figura 18. Conexión a instancia en EC2	54
Figura 19. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=13887	56
Figura 20. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=13887	56
Figura 21. Comparación de datos reales con predicciones de diferentes configuraciones id_item=13887	57
Figura 22. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=90765	57
Figura 23. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=90765	57

Figura 24. Comparación de datos reales con predicciones de diferentes configuraciones id_item=90765	58
Figura 25. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=79680	58
Figura 26 . Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=79680	58
Figura 27. Comparación de datos reales con predicciones con diferentes configuraciones id_item=79680	59
Figura 28. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=27112	59
Figura 29. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=27112	59
Figura 30. Comparación de datos reales con predicciones con diferentes configuraciones id_item=27112	60
Figura 31. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=1669	60
Figura 32. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=1669	60
Figura 33. Comparación de datos reales con predicciones con diferentes configuraciones id_item=1669	61
Figura 34. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=101609	61
Figura 35. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=101609	61
Figura 36. Comparación de datos reales con predicciones con diferentes configuraciones id_item=101609	62
Figura 37. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=54122	62
Figura 38. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=54122	62
Figura 39. Comparación de datos reales con predicciones con diferentes configuraciones id_item=54122	63
Figura 40. Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=88275	63

Figura 41. Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=88275	63
Figura 42. Comparación de datos reales con predicciones con diferentes configuraciones id_item=88275	64
Figura 43. Vista de carga de archivos dashboard.....	65
Figura 44. Vista de la interfaz gráfica con sidebar: KPIs y mapa geográfico.....	66
Figura 45. Heatmap de Cantidad de Registros por Año y Provincia	66
Figura 46. Gráfico histórico de abastecimientos, ventas y predicciones futuras	67

Índice de tablas

Tabla 1: Rendimiento en términos de persistencia, coeficiente de variación, clasificación y desempeño de eficiencia para diferentes sectores	22
Tabla 2: Cuadro comparativo de herramientas de visualización.....	25
Tabla 3: Cuadro comparativo entre plataforma Google Cloud y Microsoft Azure	26
Tabla 4: Precios de almacenamiento AWS S3.....	33
Tabla 5: Precios de almacenamiento AWS Lambda.....	34
Tabla 6: Cuadro comparativo con los valores de RMSE de train, val, test.....	64
Tabla 7: Pruebas de validación.....	68
Tabla 8: Pruebas de Rendimiento.....	69
Tabla 9: Pruebas de Robustez	69
Tabla 10: Métricas de rendimiento para evaluar la intuitividad del dashboard	70

Capítulo 1

1.1 Introducción

Actualmente en los negocios farmacéuticos se afrontan dificultades por ser una industria altamente variable. Uno de los principales distribuidores de productos farmacéuticos del país ha identificado que sus problemas derivan de la variabilidad en la demanda de sus productos, la dependencia de aprobaciones regulatorias, inventarios inadecuados y la gestión de los productos de fecha de vencimiento, en específico aquellos productos farmacéuticos sin política de devolución, lo que conlleva a la quema de los productos impactando negativamente al medio ambiente.

En un entorno empresarial tan dinámico y competitivo como el de la distribución farmacéutica, la capacidad de anticipar la demanda de productos es crucial para asegurar la eficiencia operativa y la sostenibilidad financiera. Los métodos tradicionales de gestión de inventarios y pronósticos de ventas han demostrado ser insuficientes para abordar las complejidades de este sector.

Este proyecto es importante porque brindará conocimiento para una mejor toma de decisiones, evitando dificultades de ventas a futuro. Ciertamente, al brindar una mejor calidad de servicio, se logrará fidelizar y satisfacer a los clientes, asegurando futuros ingresos. También se evitarán prácticas no amigables con el medio ambiente porque ciertos productos no son aptos para una economía circular, obligando a la empresa a incinerarlos.

La investigación será aplicada, descriptiva, correlacional, no experimental y de diseño transversal. Se usarán tanto técnicas cuantitativas como cualitativas para este estudio. Se recolectarán datos históricos sobre las ventas, el inventario de la distribuidora, la baja de inventario, y se entrevistará a los encargados del área de inventario.

1.2 Descripción del Problema

La empresa afectada es una reconocida distribuidora en el mercado nacional, conocida por su amplia gama de productos farmacéuticos. Esta empresa presenta desafíos relacionados a la gestión de inventario, afectando a la eficiencia operativa y financiera.

La falta de precisión en la estimación de ventas de productos con fecha de vencimiento plantea diversos desafíos importantes para la distribuidora. Estos desafíos incluyen inversiones desacertadas, rotación ineficiente de productos e inventarios inadecuados, lo que puede llevar tanto al agotamiento de existencias como al exceso de inventario.

El agotamiento de existencias afecta no solo a las finanzas de la empresa y a la salud pública, ya que hay medicamentos esenciales que pueden poner en riesgo la salud de los pacientes que dependen de estos insumos médicos para tratar enfermedades o alguna condición médica, aunque el cliente puede tardar en llegar de un día a una semana.

Por otro lado, el exceso de inventario también presenta problemas tanto para la empresa como para el medio ambiente. En este proyecto, se considerarán aquellos fármacos con fecha de caducidad sin políticas de devolución (no son reembolsables luego de que la empresa los compre al proveedor), además al no ser parte de un modelo económicamente circular, la empresa se ve obligada a incinerarlos. Este proceso genera costos operativos adicionales relacionados con la logística, recursos y proveedores.

Actualmente, la empresa afronta esta problemática de forma tradicional, usando métodos estadísticos, aunque es una alternativa útil, presenta limitaciones frente a la variabilidad de la industria porque no es capaz de capturar relaciones complejas y no lineales entre variables, a diferencia de los modelos de aprendizaje profundo, que modelan relaciones complejas, utilizando arquitecturas como redes neuronales profundas. Como última medida, la empresa recurre a la reducción de precios, la cual no es suficiente para abordar la problemática.

En resumen, la empresa aún presenta grandes pérdidas de dinero con un aproximado de cien mil dólares mensuales a nivel nacional, tanto por no aprovechar ventas por falta de inventario como por no vender productos por exceso de inventario. Haciendo evidente la necesidad de adoptar opciones más avanzadas y confiables como los modelos de aprendizaje profundo que ayuden a optimizar la gestión de inventario, reducir costos operativos, minimizar el desperdicio de productos y mejorar la experiencia del cliente

1.3 Justificación del Problema

Si bien se utilizan alternativas como los métodos estadísticos tradicionales, estos tienen limitaciones significativas al enfrentarse a la variabilidad y complejidad de las variables, ya que no pueden capturar relaciones complejas y no lineales entre ellas, lo que conduce a pronósticos imprecisos.

Estas pérdidas significativas de dinero pueden llevar a la empresa a una etapa de crisis financiera, obligando a hacer recorte de personal y dejando desempleadas a varias personas en el Ecuador. Además, los empleados que permanecen en la empresa se ven sobrecargados de trabajo, lo que puede afectar negativamente a su bienestar y eficiencia operativa.

Por ello es importante una solución avanzada para asegurar la continuidad y eficiencia de la distribuidora farmacéutica, mejorando su capacidad para servir a los pacientes de manera eficaz y sostenible, por estas razones, la inversión en tecnologías de IA promete una solución rentable para la empresa.

1.4 Objetivos

1.4.1 Objetivo general

Implementar un sistema de análisis predictivo mediante el uso de IA (inteligencia artificial) y aprendizaje automático, que realice pronósticos de las ventas de los diez productos seleccionados estratégicamente entre aquellos que generan mayores pérdidas a la distribuidora farmacéutica y

aquellos fundamentales para el tratamiento de enfermedades crónicas, y los muestre en un dashboard interactivo, para mejorar la precisión en las estimaciones de ventas de dichos productos.

1.4.2 Objetivos específicos

1. Implementar un algoritmo de predicción robusto y eficiente, capaz de manejar grandes volúmenes de datos con alta precisión y confiabilidad.
2. Diseñar un dashboard intuitivo que refleje los pronósticos de ventas generados por el algoritmo mediante gráficos de barra, mapa de calor y series de tiempo, que mejore la experiencia del usuario.

1.5 Marco teórico

En la industria farmacéutica, la gestión de productos caducados es esencial debido a los riesgos que estos presentan para la salud, el medio ambiente y las finanzas de la empresa. Las principales formas de desechar, procesar o inactivar estos productos son mediante depósitos en vertederos y la devolución al fabricante, lo que permite un manejo seguro y controlado. Sin embargo, estas opciones no siempre son las más responsables desde el punto de vista ambiental. Otras prácticas son la inmovilización de desechos, el vertido en sistemas de alcantarillado, la quema en recipientes abiertos y la incineración a temperatura media, cada una con sus respectivas limitaciones.

La inactivación química neutraliza los productos nocivos, mientras que la incineración a altas temperaturas en plantas industriales es considerada una de las formas más seguras y eficaces. La elección del método adecuado depende de varios factores, como la naturaleza del producto y la infraestructura disponible [1]. Bajo este contexto, la predicción precisa de la demanda de productos farmacéuticos y la gestión efectiva de inventarios se vuelven cruciales para minimizar el desperdicio y evitar el agotamiento de existencias.

1.5.1 Gestión de Inventario de la Industria Farmacéutica

La llegada de la tecnología ha revolucionado las prácticas de gestión de inventarios farmacéuticos. Tal como sistemas que incorporan la tecnología de identificación por radiofrecuencia (RFID) que ha permitido el seguimiento y monitoreo en tiempo real de los inventarios farmacéuticos, mejorando la visibilidad y la trazabilidad a lo largo de la cadena de suministro [2].

La implementación de análisis predictivo y algoritmos de IA puede mejorar significativamente la precisión en la previsión de la demanda y la optimización de los niveles de inventario, lo cual es crucial para la eficiencia operativa y la capacidad de los proveedores de atención médica de ofrecer servicios de calidad. Una gestión eficaz de inventarios, tanto de productos normales como perecederos, minimiza los riesgos asociados con la falta de stock o la caducidad de productos, protegiendo así la salud pública y garantizando la disponibilidad continua de medicamentos esenciales [3, 4].

En el caso de una distribuidora nacional de productos farmacéuticos, una gestión eficaz de inventarios que evite tanto la falta de stock como la caducidad de productos no solo protege la salud pública al asegurar la disponibilidad continua de medicamentos esenciales, sino que también reduce costos operativos y minimiza desperdicios, destacando la necesidad de adoptar tecnologías avanzadas como los modelos de aprendizaje profundo para abordar estos desafíos.

1.5.2 Demanda y variabilidad en el Sector Farmacéutico

La incertidumbre de la demanda es un desafío constante en la industria farmacéutica, influenciada por factores como las decisiones de los proveedores de atención médica y la competencia, lo que hace que una gestión eficaz del inventario sea esencial para mitigar riesgos [4, 5].

Para fortalecer la resiliencia en este sector, es fundamental mantener redes de proveedores diversificadas, niveles de existencias de seguridad y planes de contingencia, lo que permite a las

empresas adaptarse rápidamente a interrupciones en la cadena de suministro y asegurar la continuidad del suministro de medicamentos, protegiendo así la salud pública [4, 5].

En el contexto de la distribuidora farmacéutica, implementar estas estrategias junto con análisis predictivo ayudará a abordar la incertidumbre de la demanda y optimizar la gestión de inventarios.

Según el estudio de Andrews y Nishkar [6], que incluye datos de 476 empresas estadounidenses de 23 sectores entre los años 2010 y 2022, se buscó la relación entre la eficiencia de las empresas y la volatilidad financiera afecta a sus procesos, clasificados por sectores, que se puede apreciar en la Tabla 1.

Tabla 1

Rendimiento en términos de persistencia, coeficiente de variación, clasificación y desempeño de eficiencia para diferentes sectores

Sectoral performance.				
Sector	Persistence	Coefficient of variation	Classification	Efficiency performance
Consumer Goods	0.726	0.058	High Persistence, Low Volatility	Consistent
Rubber and Plastic Products	0.746	0.059	High Persistence, Low Volatility	Consistent
Chemicals	0.605	0.064	Low Persistence, Low Volatility	Stable
Construction Materials	0.613	0.041	Low Persistence, Low Volatility	Stable
Machinery	0.547	0.076	Low Persistence, Low Volatility	Stable
Food Products ^a	0.44	0.033	Low Persistence, Low Volatility	Stable
Business Supplies ^a	0.422	0.011	Low Persistence, Low Volatility	Stable
Shipping Containers ^a	0.208	0.003	Low Persistence, Low Volatility	Stable
Aircraft ^a	0.48	0.05	Low Persistence, Low Volatility	Stable
Steel Works Etc ^a	0.43	0.062	Low Persistence, Low Volatility	Stable
Petroleum and Natural Gas ^a	0.282	0.07	Low Persistence, Low Volatility	Stable
Recreation	0.269	0.048	Low Persistence, Low Volatility	Stable
Shipbuilding, Railroad Equipment	0.549	0.043	Low Persistence, Low Volatility	Stable
Medical Equipment	0.644	0.093	Low Persistence, High Volatility	Unstable
Electrical Equipment	0.669	0.117	Low Persistence, High Volatility	Unstable
Automobiles and Trucks	0.535	0.075	Low Persistence, High Volatility	Unstable
Communication ^a	0.44	0.089	Low Persistence, High Volatility	Unstable
Electronic Equipment	0.745	0.086	High Persistence, High Volatility	Erratic
Business Services	0.789	0.119	High Persistence, High Volatility	Erratic
Measuring and Control Equipment	0.716	0.078	High Persistence, High Volatility	Erratic
Pharmaceutical Products	0.87	0.241	High Persistence, High Volatility	Erratic
Computers	0.765	0.084	High Persistence, High Volatility	Erratic
Trading	0.814	0.199	High Persistence, High Volatility	Erratic

Donde se concluye que los productos farmacéuticos se caracterizan por su alta persistencia y volatilidad, lo que resulta de un desempeño errático. Esto puede deberse a diversos factores como la dependencia de aprobaciones regulatorias, la variabilidad de la demanda de productos y la innovación continua del sector.

Se puede observar que recientes investigaciones subrayan la complejidad de la gestión de ventas en la industria farmacéutica, dando a notar la importancia de adaptarse rápidamente a los cambios para manejar eficientemente la incertidumbre. La alta volatilidad observada resalta la necesidad de estrategias más robustas para la gestión de inventarios.

1.5.3 Tecnologías de análisis predictivo

La literatura existente en el campo de la gestión de inventarios ha explorado diversas metodologías y técnicas para mejorar la precisión en la predicción de la demanda, así como para optimizar la gestión de inventarios. Entre estas técnicas, destacan los enfoques basados en modelos de aprendizaje automático, como las RNN (Redes Neuronales Recurrentes) y las redes LSTM (Long short-term memory), que han demostrado ser efectivos en la predicción de series temporales en diversos contextos empresariales [7].

Las RNN procesan secuencias de datos con una arquitectura que mantiene una memoria a corto plazo de los estados anteriores, lo que les permite capturar patrones temporales importantes. Sin embargo, las RNN convencionales tienen limitaciones para recordar información a largo plazo debido al problema del desvanecimiento del gradiente. Para abordar esta limitación, se desarrollaron las LSTM, una variante avanzada de las RNN. Las LSTM incorporan celdas de memoria y mecanismos de control a través de puertas que regulan el flujo de información, permitiendo la captura de dependencias a largo plazo en los datos [8].

Estas redes, introducidas por Hochreiter y Schmidhuber en 1997, han sido refinadas a lo largo de los años para aprender dependencias a largo plazo en los datos. Conformadas por una entrada, una o más capas ocultas y una salida, las LSTM contienen células de memoria que mantienen y ajustan su estado a través de tres compuertas: de olvido, de entrada y de salida. Estas compuertas regulan la información dentro de la célula, lo que permite a las LSTM recordar secuencias largas de datos [9].

Estas metodologías ofrecen la capacidad de capturar patrones temporales complejos y dependencias a largo plazo en los datos históricos de ventas, lo que permite una predicción más precisa y granular de la venta de productos farmacéuticos. En este sentido, la aplicación de enfoques avanzados de IA en la predicción de la venta y la gestión de inventarios presenta una oportunidad significativa para mejorar la eficiencia operativa y reducir el desperdicio en la industria farmacéutica.

1.5.4 Herramientas de visualización

Las herramientas de visualización de datos son fundamentales en el entrenamiento y evaluación de modelos de aprendizaje automático. Después de entrenar el modelo, es crucial mostrar las predicciones y analizar su rendimiento. Las plataformas de visualización crean gráficos y paneles interactivos, facilitando la comprensión de los datos y la detección rápida de patrones y anomalías [10].

Por otro lado, es necesario resaltar la importancia del estado del arte de las interfaces gráficas en la construcción de un sistema de gestión de inventarios. No solo es necesario desarrollar un modelo de IA preciso, sino también diseñar una interfaz gráfica que permita a los usuarios visualizar e interactuar con los resultados del modelo. Según estudios recientes, la integración de interfaces gráficas con modelos de predicción no solo facilita la comprensión de los resultados por parte de los usuarios, sino que también mejora significativamente la toma de decisiones basada en datos [11]. Una interfaz gráfica eficaz puede representar visualmente las predicciones de demanda, tendencias y alertas, proporcionando una herramienta intuitiva y accesible para la gestión de inventarios [12].

Streamlit, Gradio y Dash son frameworks populares para crear aplicaciones web orientadas al análisis y procesamiento de datos [13]. Entre aquellas herramientas destacadas para la visualización de datos, sobresale Streamlit, una biblioteca de código abierto que permite crear aplicaciones web interactivas de manera sencilla y eficiente, tal como se aprecia en la Tabla 2, esta

herramienta es útil ya que a diferencia de las demás, no requiere de conocimientos avanzados en desarrollo front-end. Esta herramienta ha ganado popularidad recientemente debido a su capacidad para desarrollar interfaces inmersivas y fáciles de usar, lo que facilita significativamente la exploración de conjuntos de datos complejos [14, 15].

Tabla 2

Cuadro comparativo de herramientas de visualización

Criterio	Streamlit	Gradio	Dash
Instalación	Simple, sin necesidad de conocimientos de desarrollo web.	Orientado a ML con componentes predeterminados.	Más complejo, requiere conocimientos en HTML/CSS para personalización avanzada.
Personalización	Componentes integrados fáciles de usar, permite personalización básica y componentes personalizados.	Altamente personalizable en estética y organización, ideal para visualización de modelos de ML.	Gran adaptabilidad, permite HTML/CSS para un control detallado del diseño.
Comunidad	Comunidad en expansión, rica documentación y galería de ejemplos.	Comunidad activa pero más pequeña, enfocada en ML, con amplia documentación aplicada.	Respaldo de la comunidad Plotly, vasta y comprometida, rica en ejemplos y tutoriales.
Documentación	Extensa, detallada, con tutoriales y ejemplos accesibles.	Documentación amplia enfocada en ML con ejemplos prácticos.	Documentación extensa, muchos ejemplos y recursos, incluyendo cursos y webinars de Plotly.

1.5.5 Infraestructura en la nube

La infraestructura en la nube es esencial para el funcionamiento de aplicaciones modernas, proporcionando no solo recursos escalables y accesibles desde cualquier lugar, sino también una amplia variedad de servicios adaptados a necesidades específicas. Además de AWS (Amazon Web Services), existen otras plataformas como GCP (Google Cloud Platform) y Microsoft Azure, que

ofrecen soluciones especializadas para distintos tipos de aplicaciones. Estas van desde el análisis de datos y ML, hasta la gestión de aplicaciones empresariales, cada una con sus propias tecnologías y frameworks optimizados. Por ejemplo, GCP ofrece servicios como BigQuery para análisis de datos en tiempo real y Cloud AI para ML, mientras que Azure integra soluciones como Azure SQL para bases de datos empresariales y Azure Machine Learning para la creación de modelos predictivos [16]. Estas plataformas ofrecen una amplia gama de herramientas y servicios que facilitan la gestión de grandes volúmenes de datos y garantizan la continuidad operativa, adaptándose a las necesidades cambiantes de las empresas [17].

Tal como se aprecia en la Tabla 3, ambas plataformas proporcionan soluciones en computación bajo los modelos SaaS, PaaS, y IaaS, con una fuerte contribución en PaaS. En cuanto a compatibilidad con marcos de aprendizaje automático, Google Cloud ofrece soporte para TensorFlow y APIs de desarrollo integradas, mientras que Azure soporta una mayor variedad de marcos, como PyTorch, Scikit-learn, y Keras, facilitando el desarrollo de soluciones de machine learning y análisis de datos.

Tabla 3

Cuadro comparativo entre plataforma Google Cloud y Microsoft Azure

COMPARACIÓN ENTRE PLATAFORMA GOOGLE CLOUD Y MICROSOFT AZURE		
Parámetros	Google Cloud Platform	Microsoft Azure
Tipos de computación proporcionados	SaaS, PaaS e IaaS con importantes contribuciones en PaaS	SaaS, PaaS e IaaS con importantes contribuciones en PaaS
SO preconfigurado	<ol style="list-style-type: none"> 1. Cent OS 2. Debian 3. Ubuntu 4. Red Hat Linux 5. Windows Server 	<ol style="list-style-type: none"> 1. Cent OS 2. FreeBSD 3. OpenSUSE Linux 4. Oracle Linux 5. Ubuntu 6. Windows server
Marcos de aprendizaje automático compatibles	<ol style="list-style-type: none"> 1. TensorFlow 2. DistBelief 	<ol style="list-style-type: none"> 1. PyTorch 2. TensorFlow 3. Scikit-learn

	3. Muchas API integradas para respaldar el desarrollo.	4. MXNet 5. Chainer 6. Keras
Tipos de precios	Pago sobre la marcha, facturación por segundo según demanda	Precios de pago sobre la marcha

1.5.6 Impacto del análisis predictivo en la toma de decisiones

El análisis predictivo es una herramienta que tiene un impacto significativo en la toma de decisiones empresariales. Estas herramientas aumentan la precisión al agilizar los procesos, fomentar la toma de decisiones basada en datos, mejorar constantemente las estrategias y minimizar los errores de las muestras. Además de ser beneficiosas para los auditores, estas proyecciones sirven como punto de referencia mediante el cual se pueden evaluar los estados financieros de la empresa [18].

Según Wang [19], en la gestión de riesgos contemporáneo, la integración del análisis predictivo se ha convertido en una faceta crítica, influyendo en la precisión de la evaluación de riesgos y la rapidez de la gestión de riesgos en tiempo real.

Thakker [20] postula que el análisis predictivo puede ayudar a los auditores a identificar anomalías y señales de advertencia en los datos financieros. Al analizar inmensas bases de datos, los modelos predictivos pueden detectar irregularidades, discrepancias y patrones potencialmente fraudulentos. Cuando se detectan anomalías estadísticamente significativas, priorizar las investigaciones y la resolución de problemas se vuelve más sencillo para los auditores [21].

Por otro lado, Khatri [22], afirma que la capacidad del software para el análisis predictivo para manejar volúmenes sustanciales de datos, mejoran significativamente la efectividad de los procedimientos de detección de fraude.

Afirma Clarke [23], en el panorama dinámico y en rápida evolución del mundo empresarial actual, identificar y mitigar los riesgos ha adquirido una importancia primordial [24]. Integrar estas tecnologías en las empresas mejora la precisión en la toma de decisiones, detectar fraudes y gestionar riesgos en tiempo real.

Capítulo 2

2. Metodología.

En este capítulo se presenta el diseño de la solución propuesta. Se comienza con los descubrimientos obtenidos durante la ejecución del plan de recolección de datos, fundamental para garantizar la viabilidad del proyecto y la confiabilidad de la solución propuesta. A continuación, se analizan de forma exploratoria los datos recolectados y se detalla la solución mediante su arquitectura.

2.1 Plan de recolección de datos

Para la obtención de los datos se utilizaron tres datasets directamente extraídos de la base de datos de la empresa: el dataset de pérdidas por caducidad, el historial de ventas y el abastecimiento de farmacias. El dataset de pérdidas por caducidad identifica los veinte productos principales que generan las mayores pérdidas económicas debido a la caducidad, mientras que el historial de ventas contiene el registro de ventas desde el año 2016. Este historial será utilizado para predecir las ventas futuras de estos productos. El abastecimiento de farmacias proporciona información sobre los niveles de inventario de productos desde el año 2016 y permitirá prever cuándo se alcanzará el límite de abastecimiento.

Además de estos productos, se consideraron productos esenciales para el tratamiento de enfermedades crónicas, debido a su relevancia en el mercado y su impacto en la salud pública. La selección final se centró en identificar los 10 productos más críticos, a partir de los productos del top 20 de averiados y aquellos relacionados con el tratamiento de enfermedades. Este enfoque permitió realizar una evaluación integral y orientada tanto al impacto económico como a la importancia sanitaria.

2.2 Fiabilidad de datos

Los datos utilizados en este proyecto son altamente confiables, ya que provienen de registros directos de ventas y abastecimientos de farmacias en operación, lo que garantiza su precisión y veracidad. Para asegurar la calidad de los datos, se implementaron rigurosos

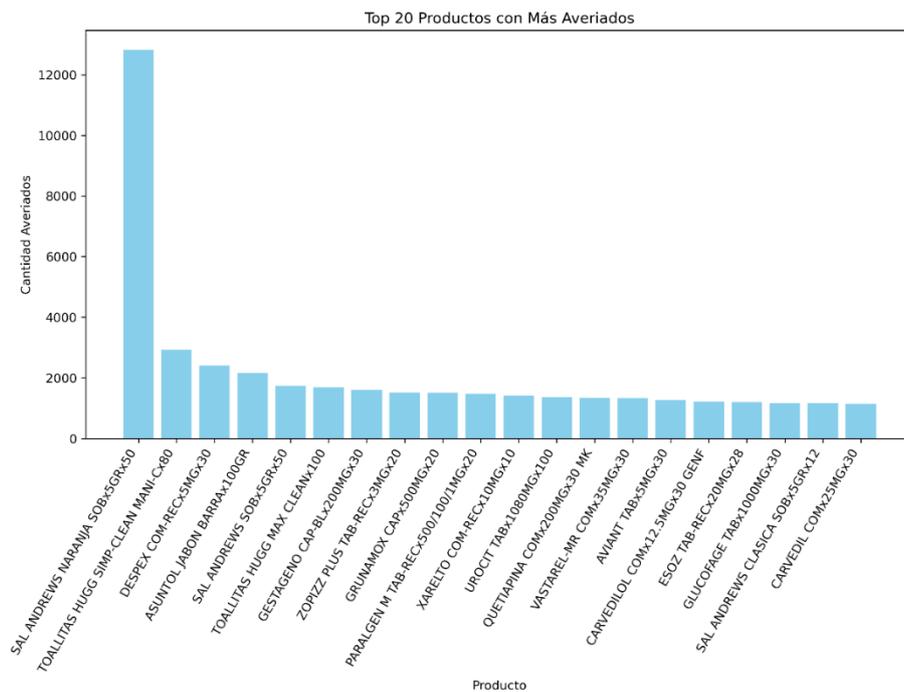
mecanismos de preprocesamiento que incluyeron la identificación y eliminación de valores nulos o inadecuados, así como la verificación de la consistencia y coherencia en el dataset. Este enfoque permitió mantener un estándar elevado de calidad de los datos a lo largo de todo el proceso analítico, lo cual es fundamental para obtener resultados precisos y significativos en el análisis predictivo.

2.3 Análisis exploratorio de datos

Durante la fase de análisis exploratorio de datos, se llevó a cabo un estudio sobre el dataset que contiene información acerca de las pérdidas ocasionadas por productos caducados en la empresa. El objetivo fue identificar los 20 productos principales que causan estas pérdidas. La Figura 1 presenta un gráfico que ilustra estos productos junto con la cantidad de unidades caducadas, visualizando los principales generadores de pérdidas por caducidad.

Figura 1

Top 20 productos que generan pérdidas a la empresa organizados por cantidad de caducados



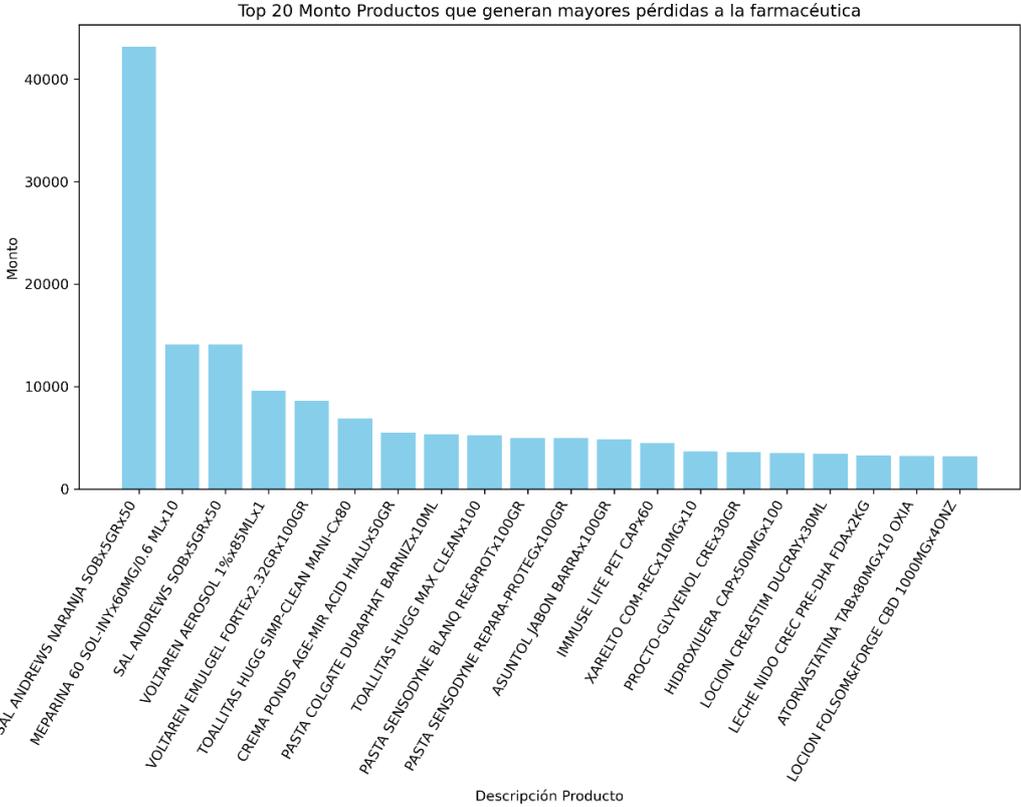
Paralelamente, se realizó un análisis para identificar productos que son críticos para el tratamiento de enfermedades crónicas. Estos productos se seleccionaron debido a su importancia en el cuidado de la salud y su necesidad constante en el mercado. La combinación de ambos análisis permitió seleccionar un conjunto de 10 productos, que serán utilizados para realizar predicciones de ventas.

Por otro lado, también se realizó un estudio sobre el dataset mencionado anteriormente, clasificando el Top 20 según el monto total de pérdidas generadas por productos caducados.

La Figura 2 exhibe un gráfico que ilustra esta información, resaltando casos donde ciertos productos pueden ocasionar pérdidas económicas significativas. Estos escenarios podrían conducir a una sobreproducción de inventario y a un considerable deterioro financiero.

Figura 2

Top 20 productos que generan mayores pérdidas para la empresa por motivos de caducidad organizados por valor total de pérdida



Por esta razón, fue crucial considerar el segundo análisis en el desarrollo del algoritmo de predicción de ventas, ya que categoriza los productos según las pérdidas económicas que generan para la empresa en función de su valor monetario. Aunque algunos productos tienen menos unidades caducadas, su alto valor en el mercado provoca pérdidas significativas. Este análisis fue esencial para seleccionar los productos que se utilizaron en las predicciones. Este enfoque integral aseguró que la selección final de productos no solo minimice las pérdidas económicas, sino que también maximice el impacto positivo en la salud pública.

2.4 Propuesta de solución

La arquitectura del proyecto de pronóstico de ventas se construyó utilizando varios servicios de AWS para crear un sistema robusto y escalable. Por otro lado, el modelo de predicción se fundamentó en una red neuronal LSTM, diseñada específicamente para procesar y analizar series temporales. Utilizando técnicas avanzadas de ML (Machine Learning), el modelo fue entrenado con datos históricos de ventas para generar predicciones precisas sobre el comportamiento futuro de las ventas. Este enfoque combinó la capacidad de las LSTM para identificar patrones en datos secuenciales con la precisión de las técnicas de ML, optimizando así la predicción de ventas basadas en datos históricos [25].

Como se muestra en la Figura 3, la arquitectura del sistema consta de varios módulos que trabajan en conjunto para llevar a cabo un correcto funcionamiento de este.

- **Streamlit:** Este módulo se ejecuta en una instancia de AWS EC2, donde se aloja una aplicación basada en la librería Streamlit. Es la interfaz principal del sistema, encargada de permitir al usuario cargar los archivos de ventas y abastecimientos. Dentro de esta aplicación se generan y muestran las gráficas, los indicadores clave de rendimiento (KPI), el mapa de calor y las series de tiempo.

Este módulo actúa como punto de inicio del flujo de trabajo, enviando los archivos cargados a un bucket en AWS S3. Una vez en S3, los datos son procesados por AWS Lambda y Flask. Tras la finalización del procesamiento, la aplicación recupera los resultados de las predicciones y los visualiza junto a las gráficas de ventas y abastecimientos, proporcionando al usuario una visión integral de la información.

- **AWS S3:** Este módulo recibe el archivo de ventas enviado desde la aplicación Streamlit y lo almacena en un bucket. Los archivos enviados desde Streamlit incluyen un identificador único adjunto al nombre del archivo, lo que permite a AWS Lambda y a la aplicación Flask identificar cuál archivo debe ser procesado según su nombre.
 - Amazon S3 es un servicio de almacenamiento en la nube que ofrece escalabilidad, disponibilidad de datos y un rendimiento robusto. Es ideal para almacenar y recuperar grandes volúmenes de datos desde cualquier lugar del mundo. Además, S3 permite diferentes clases de almacenamiento según las necesidades del usuario. Tal como se muestra en la Tabla 3, el costo del almacenamiento en S3 varía dependiendo de la clase. Por ejemplo, el almacenamiento estándar cuesta \$0.023 por GB para los primeros 50 TB al mes, mientras que S3 Glacier es más económico, pero está optimizado para almacenamiento a largo plazo y acceso menos frecuente [26, 27].

Tabla 4

Precios de almacenamiento AWS S3

Precios de almacenamiento	
S3 Standard: almacenamiento de propósito general para cualquier clase de datos que se utiliza generalmente para datos a los que se accede con frecuencia	
Primeros 50 TB/mes	0,023 USD por GB
Siguientes 450 TB/mes	0,022 USD por GB
Más de 500 TB/mes	0,021 USD por GB

- **AWS lambda:** Este módulo se encarga de procesar automáticamente los archivos que llegan al bucket de S3. Cuando un archivo es cargado en S3, se activa un evento de tipo PUT que desencadena la función Lambda. Esta función realiza el procesamiento inicial de los archivos subidos, identificándolos según un identificador único en el nombre del archivo. Posteriormente, Lambda envía los datos mediante una solicitud HTTP POST a la aplicación Flask para generar las predicciones.
 - AWS Lambda permite ejecutar código sin tener que aprovisionar ni gestionar servidores. Es una solución de computación sin servidor que ejecuta funciones en respuesta a eventos y automáticamente gestiona los recursos de computación. Tal como se puede apreciar en la Tabla 5 AWS Lambda ofrece una estructura de precios diferenciada según la arquitectura utilizada y el nivel de procesamiento mensual. Los costos varían tanto en la duración de la ejecución (medida en GB/segundo) como en el número de solicitudes. [28, 29].

Tabla 5

Precios de almacenamiento AWS Lambda

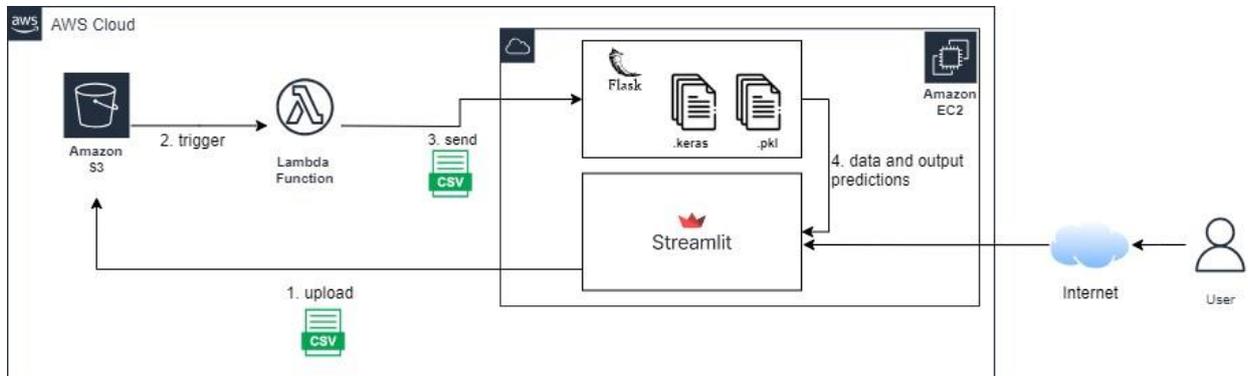
Arquitectura	Duración	Solicitudes
Precio de x86		
Primeros 6 mil millones de GB/segundo por mes	0,0000166667 USD por cada GB/segundo	0,20 USD por un millón de solicitudes
Próximos 9 mil millones de GB/segundo por mes	0,000015 USD por cada GB/segundo	0,20 USD por un millón de solicitudes
Más de 15 mil millones de GB/segundo por mes	0,0000133334 USD por cada GB/segundo	0,20 USD por un millón de solicitudes
Precio de Arm		
Primeros 7,5 mil millones de GB/segundo por mes	0,0000133334 USD por cada GB/segundo	0,20 USD por un millón de solicitudes
Próximos 11,25 mil millones de GB/segundo por mes	0,0000120001 USD por cada GB/segundo	0,20 USD por un millón de solicitudes
Más de 18,75 mil millones de GB/segundo por mes	0,0000106667 USD por cada GB/segundo	0,20 USD por un millón de solicitudes

- **Flask:** Esta aplicación, alojada en una instancia de AWS EC2 se encarga de generar las predicciones. Al recibir los datos desde AWS Lambda, Flask carga los modelos de predicción almacenados en archivos .keras y .pkl, los cuales contienen los pesos y parámetros entrenados de los modelos. Con esta información, genera predicciones basadas en los datos proporcionados y expone los resultados a través de un endpoint HTTP. Posteriormente, la aplicación Streamlit consume este endpoint para mostrar los resultados junto con otros datos relevantes.
 - AWS EC2 es utilizado en el sistema para proporcionar capacidad de computación escalable. Permite lanzar y gestionar instancias virtuales que se configuran de acuerdo con las necesidades específicas de la aplicación, ofreciendo control total sobre el entorno. El costo de EC2 varía según el tipo de instancia y la región. Por ejemplo, una instancia t2.micro, parte del nivel gratuito, cuesta alrededor de \$0.0116 por hora en la región de EE. UU. Este. Otros tipos de instancias, como las reservadas o spot, tienen diferentes estructuras de precios [30, 31].

En resumen, el flujo del sistema comienza cuando el usuario carga un archivo CSV en la aplicación Streamlit, que está alojada en una instancia de AWS EC2. Este archivo es enviado automáticamente a un bucket de Amazon S3, lo que activa una función AWS Lambda para preparar los datos y enviarlos a la aplicación Flask, que se encuentra en otra instancia de EC2. Flask utiliza los archivos del modelo LSTM (.keras y .pkl) para realizar predicciones basadas en los productos especificados en el CSV. Finalmente, las predicciones son devueltas a la aplicación Streamlit, donde se presentan junto con otras visualizaciones interactivas. Como se mencionó previamente, en este sistema se seleccionaron 10 productos, priorizando aquellos que generan mayores pérdidas por caducidad y productos esenciales para el tratamiento de enfermedades crónicas.

Figura 3

Arquitectura propuesta de solución



En la Figura 4 se puede apreciar el diagrama de actividades en donde se especifican los pasos que el usuario final deberá seguir para poder interactuar con el mismo. El diagrama ilustra el proceso mediante el cual un usuario interactúa con un dashboard de predicciones. Comienza con la apertura del navegador y el acceso a la URL del dashboard, donde el usuario ingresa el CSV correspondiente para generar las predicciones. A continuación, el usuario visualiza las predicciones en el dashboard y tiene la opción de aplicar filtros adicionales, como rango de fechas o productos específicos para refinar la visualización. Finalmente, el usuario puede ver el dashboard actualizado con los filtros aplicados, permitiendo una visualización más enfocada y relevante según los criterios seleccionados.

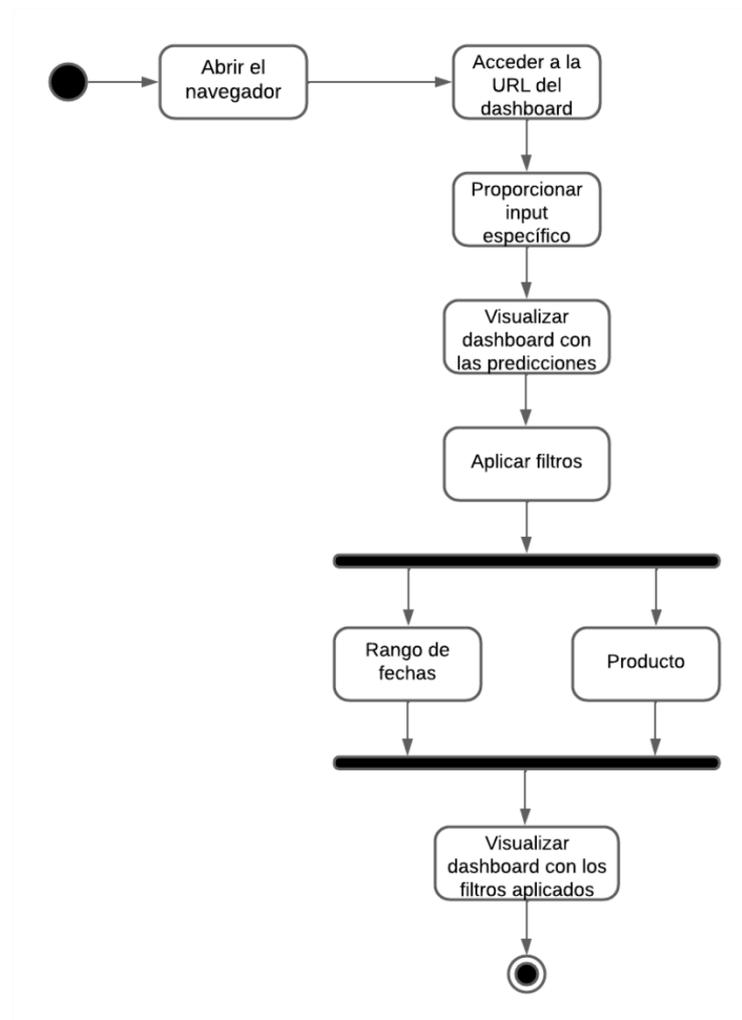
El usuario podrá aplicar una variedad de opciones de filtrado para personalizar la visualización de datos. Entre estas opciones se destacan:

1. Filtro por producto: Permite la selección de un producto específico, generando gráficas basadas exclusivamente en los datos de dicho producto.
2. Filtro de rango temporal: Posibilita la delimitación de un período de tiempo específico, ajustando las gráficas del producto seleccionado al intervalo de fechas establecido.

Estos filtros, aplicables de manera individual o combinada, proporcionarán a los usuarios una herramienta flexible y potente para el análisis detallado de datos según sus necesidades específicas.

Figura 4

Diagrama de actividades



Capítulo 3

3. Resultados y análisis

En esta sección se presentan los resultados y el análisis del desarrollo del sistema predictivo de ventas. Se inicia con la identificación de los requerimientos, donde se determinaron las necesidades funcionales y no funcionales esenciales para garantizar el cumplimiento de objetivos.

A continuación, se describe la implementación del prototipo, que sirvió como base para validar y refinar las funcionalidades del sistema antes de su desarrollo completo. Finalmente, se detalla la solución implementada, que integra técnicas avanzadas de ML y tecnologías de visualización para predecir y analizar ventas en la industria farmacéutica, cumpliendo con los requerimientos establecidos y optimizando la gestión de inventarios.

3.1 Toma de requerimientos

Para el desarrollo del sistema predictivo de ventas en la industria farmacéutica, se llevó a cabo un proceso exhaustivo de toma de requerimientos que permitió identificar las funcionalidades clave necesarias para el sistema. Se establecieron requerimientos funcionales específicos que garantizarán que el sistema permita a los usuarios exportar, filtrar, y visualizar los resultados de las predicciones de ventas de manera efectiva. Asimismo, se definieron requerimientos no funcionales que asegurarán un rendimiento óptimo, una interfaz intuitiva, y la capacidad de manejar grandes volúmenes de datos, todo ello alineado con las necesidades operativas de la industria.

3.1.1 Requerimientos funcionales

- El sistema permitirá a los usuarios exportar los resultados mostrados en el dashboard.
 - El usuario podrá exportar resultados en formato CSV.
- El sistema permitirá a los usuarios filtrar los resultados mostrados en el dashboard.
 - El usuario podrá aplicar los filtros por: fecha y producto.
- El sistema permitirá a los usuarios obtener una vista de los resultados de manera general.

- El usuario podrá apreciar en dicha vista: indicadores claves de rendimiento, gráficos estadísticos y mapas de calor para identificar regiones en donde existe una alta o baja cantidad de ventas.
- El sistema permitirá a los usuarios obtener las gráficas de forma local.
 - El usuario podrá guardar los gráficos obtenidos de manera independiente en formato de imagen.

3.1.2 Requerimientos no funcionales

- El sistema debe generar predicciones de manera eficiente, asegurando una experiencia de usuario fluida y sin demoras perceptibles.
- El sistema debe ser capaz de manejar un aumento en el volumen de datos, permitiendo el procesamiento y análisis de grandes conjuntos de datos sin comprometer su rendimiento.
- El sistema debe contar con una interfaz intuitiva, permitiendo que los usuarios interactúen con el dashboard sin necesidad de capacitación avanzada.

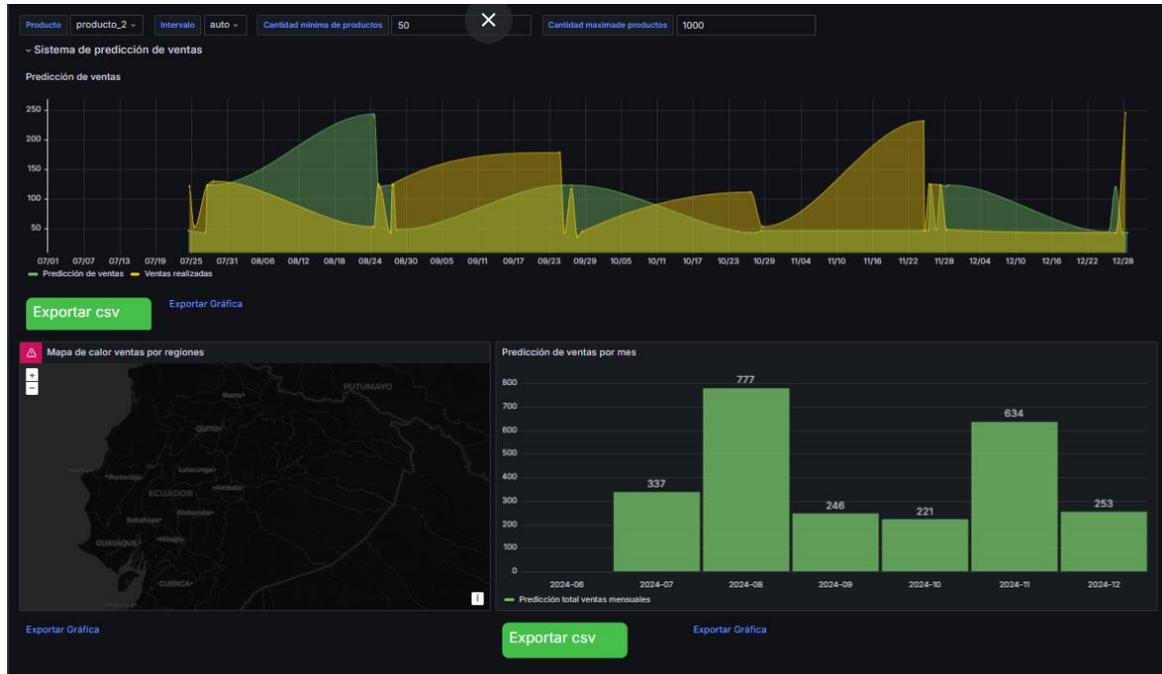
3.2 Implementación de prototipo

Para la implementación del prototipo se utilizó herramientas como Grafana, que permitió canalizar la información desde una fuente de datos previamente definida y visualizarla a través de gráficos estadísticos. Estos gráficos proporcionan una representación clara de las ventas y predicciones de los distintos productos, facilitando el análisis y la toma de decisiones.

En el prototipo diseñado, al iniciar la aplicación, el usuario visualiza todas las gráficas, cada una con un significado particular. Tal como se puede apreciar en la Figura 5, el prototipo incluye una gráfica de series temporales que representa las ventas realizadas junto con sus predicciones. En este gráfico, el eje “x” muestra el tiempo transcurrido, mientras que el eje “y” refleja la suma de productos vendidos por días o meses. Además, se incluye un mapa de calor geográfico que indica las áreas donde se han realizado las ventas, así como un diagrama de barras que muestra las predicciones mensuales de ventas.

Figura 5

Vista del Dashboard – Prototipo



Cada una de las gráficas del prototipo cuenta con cuatro tipos de filtros: uno para seleccionar un producto específico, otro para definir un intervalo de fechas, un filtro para visualizar la cantidad mínima de productos vendidos, y otro para la cantidad máxima. Al seleccionar un producto, las gráficas correspondientes se actualizan automáticamente. Todos los filtros están ubicados en la parte superior izquierda del dashboard, proporcionando una interfaz intuitiva y eficiente.

3.3 Implementación de la solución

En la implementación de la solución, inicialmente se consideró el uso de InfluxDB junto con Grafana para servir como fuente de datos y generar las gráficas correspondientes. Sin embargo, durante el transcurso del proyecto, se optó por utilizar conjuntos de datos en lugar de realizar una conexión directa con la base de datos de la empresa, esto por motivos de seguridad. Además, se identificaron ciertas limitaciones en estas herramientas, particularmente en la integración de

gráficas dentro de la aplicación y en la capacidad para visualizar grandes volúmenes de información.

Estas limitaciones motivaron la exploración de alternativas que ofrecieran mayor flexibilidad y escalabilidad. Como resultado, se optó por incorporar herramientas como Streamlit, que, en combinación con diversos servicios de AWS ofrecieron un entorno más robusto y adaptado a las necesidades del proyecto. Este enfoque permitió superar las barreras iniciales y lograr una solución más eficiente y escalable.

3.3.1 Implementación de modelo LSTM

Al plantearse como objetivo la generación de predicciones de ventas, la elección de una red neuronal LSTM fue la más adecuada dada su capacidad para capturar patrones en series temporales. En este caso, al tener 10 productos, se optó por diseñar una arquitectura de modelo unificada, seguida de un entrenamiento independiente para cada producto. Este enfoque permitió ajustar los hiperparámetros específicos para cada caso, optimizando así los resultados obtenidos.

Para implementar el modelo, se siguió una secuencia de pasos que se detalla a continuación:

1. Consideraciones iniciales del dataset

Durante este proceso, también se identificaron productos que no contaban con un registro de ventas muy antiguo, ya que eran productos relativamente nuevos en el mercado. Debido a la insuficiencia de datos históricos necesarios para un entrenamiento efectivo del modelo, estos productos fueron excluidos de la selección final para el análisis. Este enfoque permitió concentrar los esfuerzos en aquellos productos con suficiente historial de venta

2. Lectura del set de datos

Se procedió a la carga de los datos desde archivos CSV utilizando la librería “pandas”. Se definió la ruta del archivo y se especificó el delimitador adecuado (;). A

continuación, se leyó el archivo correspondiente a las ventas totales de productos y se almacenaron los datos en un DataFrame para su posterior análisis.

3. Preprocesamiento

Se identificaron seis variables clave en el dataset: 'Fecha', 'Provincia', 'id_item', 'cantidad_frac' y 'cantidad_unid'. Las variables 'cantidad_frac' y 'cantidad_unid' que representan la cantidad de unidades vendidas. 'cantidad_frac' se refiere a la venta unitaria de productos que se venden en conjunto o en cajas. Para simplificar el análisis, se decidió unificar estas dos variables en una sola, convirtiendo todas las ventas a fracciones respectivamente cuando el producto se vendió por unidad, permitiendo así trabajar de manera uniforme con una única variable.

Se llevaron a cabo 5 tareas clave, manejo de datos faltantes, ajuste de la periodicidad del dataset, escalamiento, generación del dataset supervisado y codificación de la variable tiempo.

En el manejo de series temporales, es crucial abordar los datos faltantes y ajustar la periodicidad para garantizar la consistencia temporal. Los registros vacíos fueron reemplazados por 0, lo que refleja la ausencia de ventas en esos días ayudando a mantener un intervalo de tiempo uniforme de un día en toda la serie temporal.

Para el escalamiento de los features, se aplicaron varios métodos, incluyendo Min-Max Scaler, Robust Scaler y Standard Scaler. En la que se obtuvieron mejores resultados con el método de Min-Max Scaler, escalando los features en un rango de -1 a 1.

a. Codificación de la variable tiempo

En el dataset, cada registro incluye una marca temporal detallada que abarca día, mes, año, hora, minuto y segundo. Dado que las horas, minutos y segundos se fijan en cero y no aportan información relevante para el análisis, se optó por eliminarlos y conservar únicamente la fecha (día, mes y año). Esta simplificación

permite enfocarse en los datos más relevantes y facilita el procesamiento sin perder precisión en la representación temporal.

Por esta razón, se propuso identificar cuáles de estas variables temporales realmente influían en las predicciones. Una herramienta clave en este proceso fue la Transformada de Fourier [32], que permitió descomponer la serie temporal y descubrir los componentes que se repiten con cierta regularidad. Estos elementos cíclicos son significativos para comprender el comportamiento subyacente de los datos.

Antes de aplicar la transformada, se aseguró que los registros estuvieran espaciados de manera regular, ya que cualquier irregularidad podría distorsionar los resultados. En este caso, los datos estaban organizados en intervalos diarios.

Tomando como ejemplo el producto con idItem 88275 Figura 6 se observa que, aunque podría haber cierta periodicidad en las ventas, no era sencillo determinar si estaba ligada al año, mes o día. Al aplicar la Transformada de Fourier, se descubrió tres picos significativos en el espectro de frecuencias: $frec1 = 0.03296$, $frec2 = 0.28576$ y $frec3 = 0.42848$ Figura 7.

Figura 6

Gráfico año v.s cantidad idItem=88275

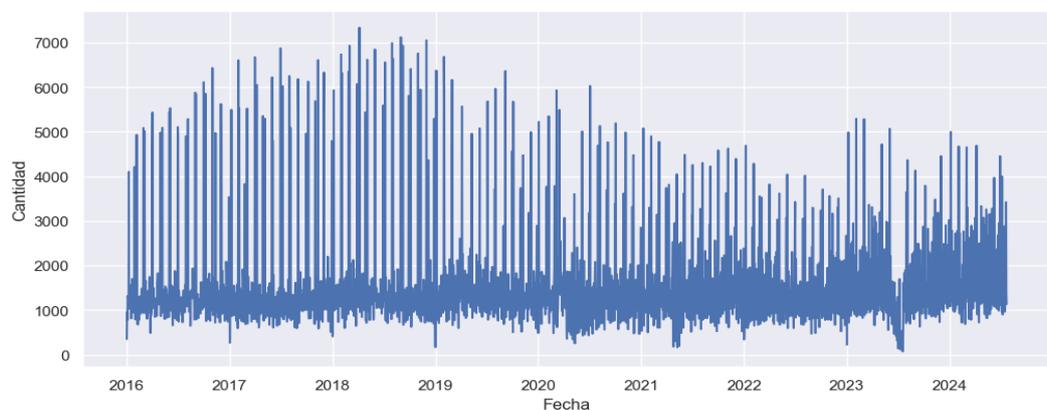
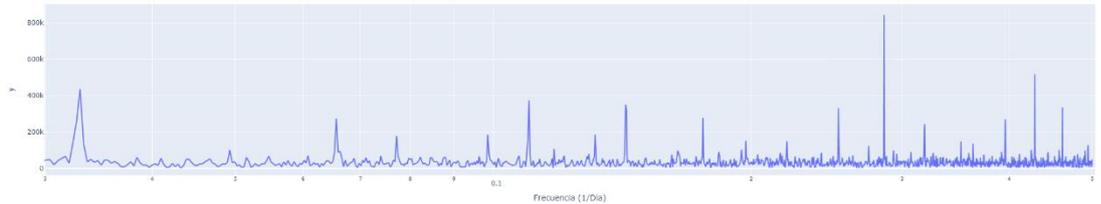


Figura 7

Espectro de frecuencias idItem=88275



Pero, en este caso no es de interés la frecuencia de tiempo la idea es ver a que instante de tiempo o a que variables de tiempo corresponde, día, mes, semanas, años, etc. Para hallar esta equivalencia se debe ocupar una formula sencilla que es calcular el valor inverso (para pasar de frecuencia a tiempo) Ecuación 1.

Ecuación 1

Cálculo del Tiempo a partir de la Frecuencia

$$T = \frac{1}{f}$$

$$frec1 = 0.03296$$

$$frec2 = 0.2857$$

$$frec3 = 0.42848$$

$$T = \frac{1}{0.03296} = 30.34 \text{ días}$$

$$T = \frac{1}{0.2857} = 3.50 \text{ días}$$

$$T = \frac{1}{0.42848} = 2.34 \text{ días}$$

Como se puede observar hay una frecuencia que equivale a 30 días que prácticamente es 1 mes, por lo que se puede concluir que para este producto el mes es relevante.

Sin embargo, no se puede utilizar directamente los valores originales de las variables temporales (por ejemplo, años como 2016, 2017, 2018 o meses como 1, 2, 3). Estos valores, al ser monótonamente crecientes, pueden dificultar la detección de patrones por parte del modelo LSTM y generar problemas con los saltos de valor, especialmente entre días y meses Figura 8. Para mitigar esto, se representa las variables temporales mediante funciones seno y coseno, lo que nos permite suavizar estos saltos y mantener la naturaleza cíclica de los datos.

Figura 8

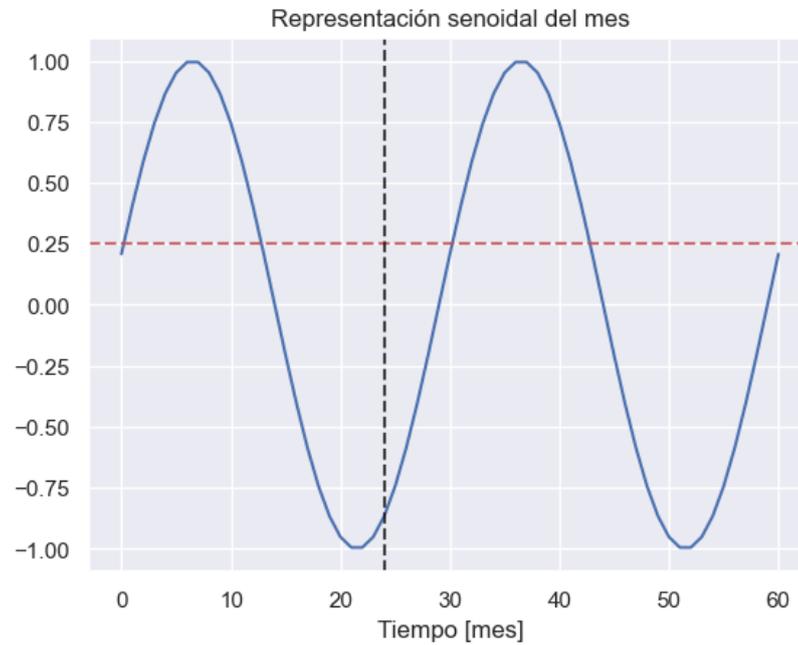
Dificultades al utilizar variables temporales [33]



En la Figura 9 se puede observar cómo la representación senoidal de los datos continúa de manera lógica después del mes 12, en contraste con la versión original de los datos, donde después del mes 12 se reiniciaba el ciclo en el mes 1. En la gráfica, la continuidad de los valores para los meses 13 y 14 se visualiza a través del flujo continuo de la curva. Sin embargo, la función seno, aunque representa correctamente la periodicidad, tiene una limitación: meses distintos pueden compartir el mismo valor (por ejemplo, los meses 13, 30 y 60 tienen un valor de 0.25, indicado por la línea horizontal roja). Esta duplicación de valores es el resultado de la naturaleza periódica de la función seno, por lo que se debe complementar con una función coseno para obtener una codificación temporal más precisa y única para cada mes.

Figura 9

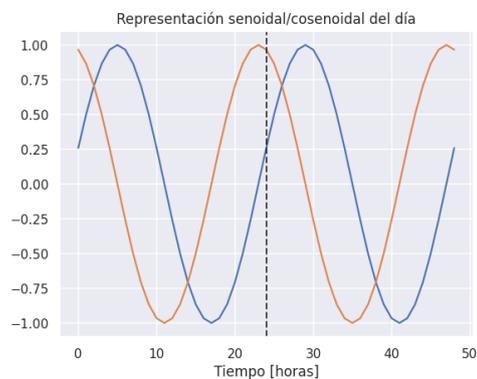
Gráfica Senoidal de Datos Mensuales a lo Largo del Tiempo



Con la codificación senoidal y cosenoidal cada instante de tiempo es codificado con un valor único, ahora el mes 13, 30, 60 tienen 2 valores únicos para representarlos Figura 10.

Figura 10

Gráfica Senoidal y Cosenoidal de Datos Mensuales a lo Largo del Tiempo



Finalmente, estos dos valores son ingresados en el dataframe Figura 11, para luego ser procesados en el modelo, cabe mencionar que estos valores no van a ser escalados debido a que ya se encuentran en el valor de 1 y -1 Figura 12.

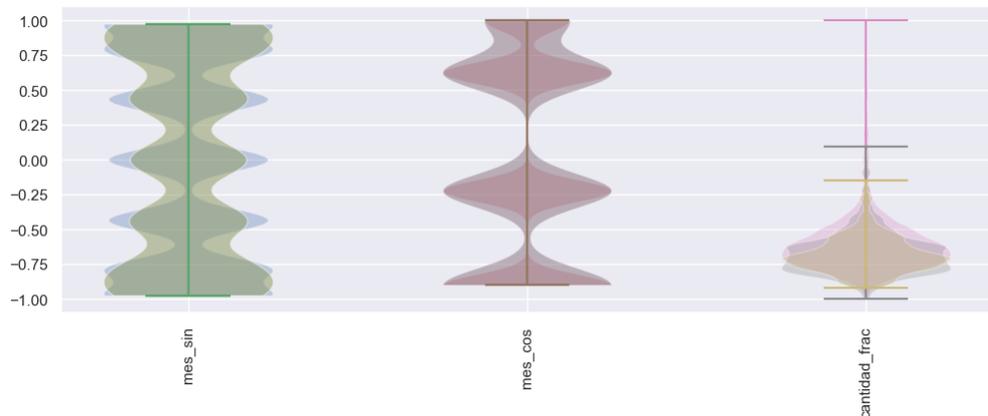
Figura 11

Dataframe con los valores codificados

	id_item	cantidad_frac	mes_sin	mes_cos
Fecha				
2016-01-01	88275	352	0.207912	0.978148
2016-01-02	88275	957	0.406737	0.913545
2016-01-03	88275	781	0.587785	0.809017
2016-01-04	88275	1321	0.743145	0.669131
2016-01-05	88275	1194	0.866025	0.500000
...

Figura 12

Gráfico de violín de los features del modelo escalados

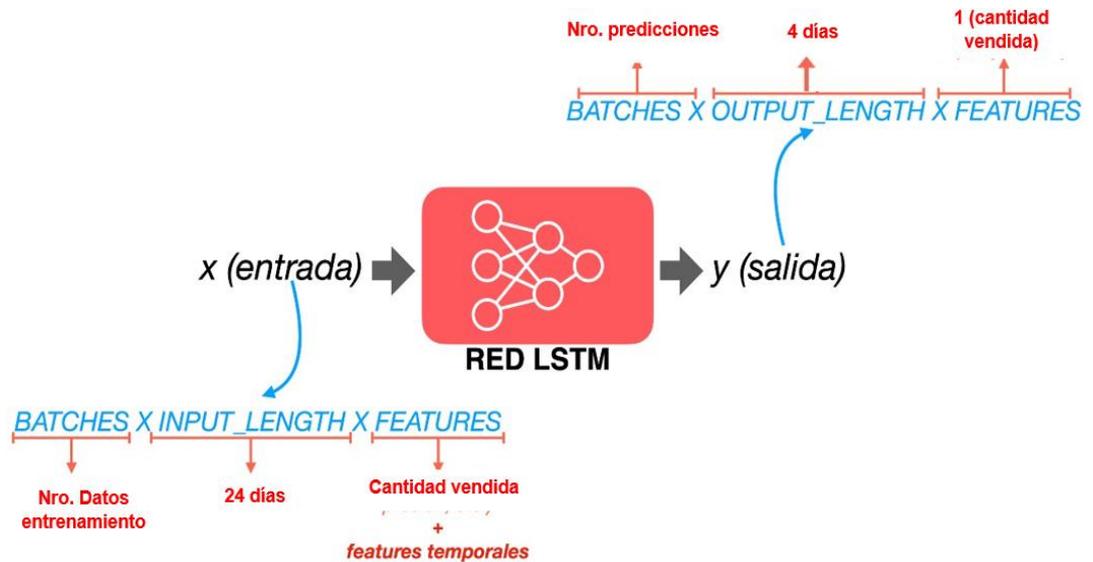


b. Generación de dataset supervisado

Para la generación del dataset supervisado se debe ajustar el set de datos de acuerdo con las especificaciones de Tensorflow/Keras para redes LSTM. Se debe tener 3 dimensiones para la entrada y salida. Como se puede ver en la Figura 13 se tiene n cantidad registros (BATCHES) que representan bloques, en la cual cada registro tiene 24 días como periodo, Output_lenght representa el número de días que se quiere predecir a futuro es decir 4 días, por último, se tiene como features la cantidad de productos vendidos, además de los features temporales.

Figura 13

Entrada y salida del modelo



Quedando de esta forma para cada dato de entrenamiento Figura 14

Un arreglo de 24 días x 1 feature + 3 features temporales (el feature temporal dependerá del comportamiento del producto).

- Un arreglo de 4 días x 1 features, que corresponde al día 25, 26, 27, 28 a predecir.

Una vez definido el formato del modelo LSTM, se inicializan dos listas: X y Y. Luego, se recorre el arreglo de datos para crear los subconjuntos de entrada X y sus correspondientes salidas Y. En cada posición i del conjunto de datos, se extrae una ventana de tamaño fijo ($input_length$) para X (que contiene los datos utilizados para la predicción) y su correspondiente salida Y (que representa los siguientes $output_length$ instantes a predecir).

Finalmente, las listas X y Y se convierten en arreglos de NumPy para los tres conjuntos de datos (tr , vl , y ts), utilizando los hiperparámetros $input_length$ y

output_length. Un ejemplo de los tamaños resultantes para las entradas y salidas quedan de la siguiente forma:

Tamaños entrada (BATCHES x INPUT_LENGTH x FEATURES) y de salida (BATCHES x OUTPUT_LENGTH x FEATURES)

Set de entrenamiento - x_{tr} : (2467, 24, 3), y_{tr} : (2467, 4, 1)

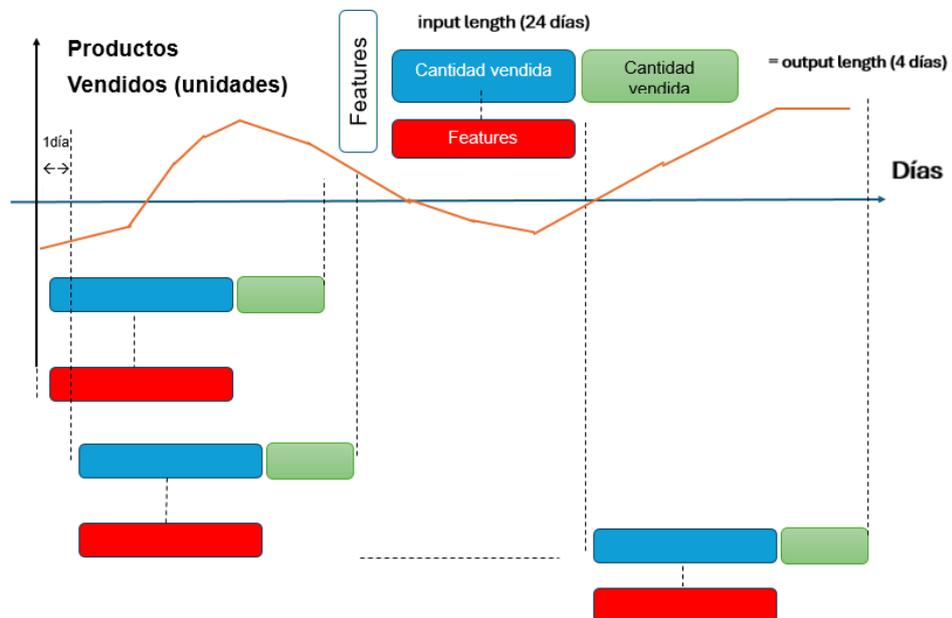
Set de validación - x_{vl} : (279, 24, 3), y_{vl} : (279, 4, 1)

Set de prueba - x_{ts} : (280, 24, 3), y_{ts} : (280, 4, 1)

En este caso se tomó de ejemplo un producto que tiene 3 features, con un input_length de 24 y un output_length de 4.

Figura 14

Proceso de predicción de cantidades vendidas con LSTM



c. Partición del set en entrenamiento, validación y prueba

Se dividió el dataset en tres conjuntos: entrenamiento (80%), validación (10%), y prueba (10%). Esta partición se realizó de manera secuencial para

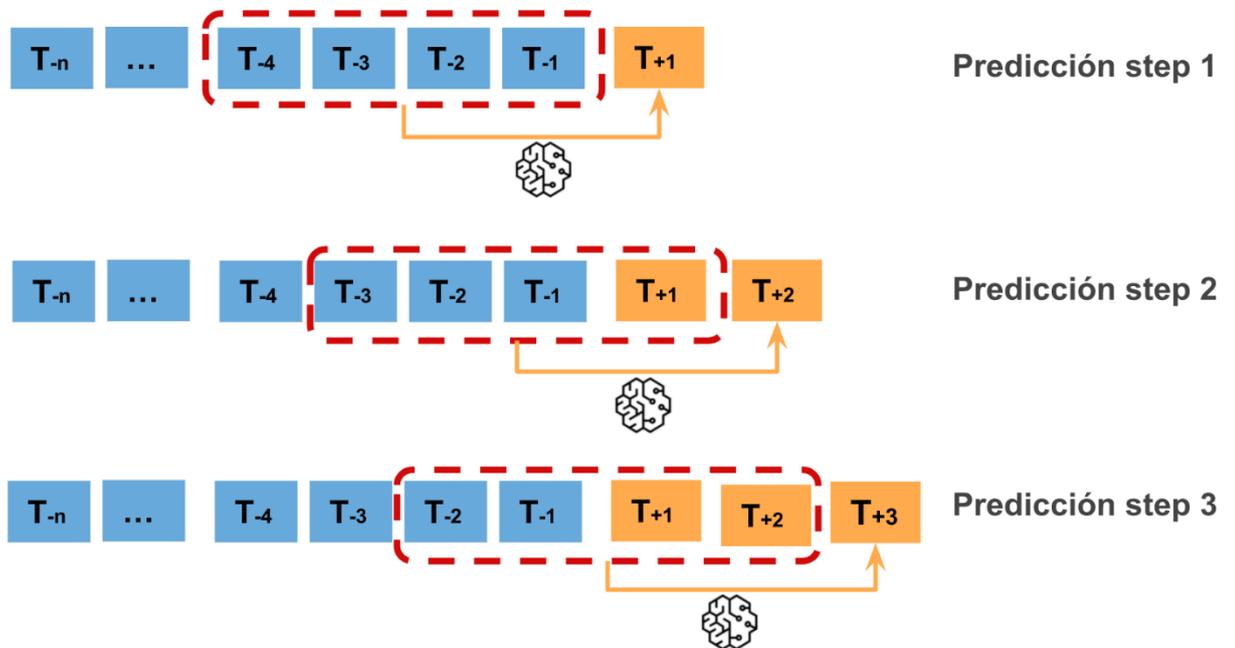
preservar la naturaleza temporal de los datos, lo cual es fundamental en modelos de series de tiempo.

4. Creación y entrenamiento del modelo

Se desarrolló un modelo LSTM multivariado multistep. Donde el modelo recibe secuencias de x días que incluye la cantidad vendida y otros features temporales con el objetivo de generar las predicciones de cantidades vendidas para los próximos 4 días. Para generar las predicciones multi-step, se utilizó la estrategia de “Recursive multistep forecasting” en la cual cada nueva predicción, hace uso de la predicción anterior [34], como se puede apreciar en la Figura 15

Figura 15

Diagrama del proceso de predicción multi-step recursivo, para predecir 3 steps a futuro utilizando los últimos 4 lags de la serie como predictores [34]



La infraestructura del modelo se compone de dos capas LSTM con 126 unidades y 66 unidades, cada una seguida de una capa de Dropout que es el encargado de identificar los patrones a lo largo del tiempo, luego se incorporó una capa de dropout con un rango de

0.1 y 0.4 dependiendo del producto, esto es importante para que ayude a evitar que el modelo se sobreajuste demasiado a datos específicos con los que se entrena. Finalmente se tiene la capa dense con 4 unidades y con una activación sigmoid.

Durante el entrenamiento se ajustan los hiperparámetros del modelo según el producto como es el batch size o las epochs. Se utilizó la función RMSE (error cuadrático medio) para medir la pérdida entre las predicciones y los valores reales. Como optimizador se utilizó Adam, algoritmo utilizado especialmente en problemas de series temporales o donde se tienen características estacionales o ruidosas, se ajusta dinámicamente la tasa de aprendizaje ($5e-5$ o 0.0002) para cada parámetro.

3.3.2 Implementación del dashboard

Para el proyecto de pronóstico de ventas, la implementación de la interfaz gráfica en Streamlit se centró en utilizar una instancia EC2 de AWS para tener un control total sobre la configuración y despliegue. Dado que el proyecto maneja millones de registros, se optó por una instancia de la familia M2, que ofrece un balance ideal entre CPU, memoria y costo. Con 16 GB de RAM, esta instancia es adecuada para manejar grandes volúmenes de datos, proporcionando suficiente potencia computacional y memoria para realizar los cálculos necesarios de manera eficiente.

Se organizó el proyecto asegurándose de que todos los archivos y dependencias estuvieran listos para funcionar en un entorno de producción. Después, se configuró la instancia instalando los paquetes necesarios y ajustando la configuración del servidor para que la aplicación de Streamlit estuviera optimizada y accesible. Además, se configuró la red y los puertos necesarios para asegurar que la interfaz gráfica fuera accesible desde la web sin problemas.

El uso de la instancia M2 permitió no solo optimizar el rendimiento para manejar los millones de registros involucrados, sino también mantener un control sobre los costos, asegurando que el entorno fuera escalable y seguro. Esto garantizó que la interfaz gráfica estuviera lista para

ser utilizada por los usuarios, permitiéndoles interactuar de manera fluida con las predicciones de ventas, incluso cuando se procesan grandes volúmenes de datos.

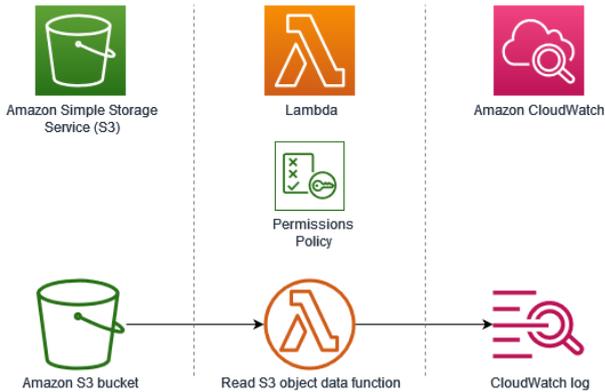
3.3.3 Implementación de arquitectura en AWS

Los servicios de AWS desempeñaron un papel importante en la implementación del sistema, especialmente los servicios AWS S3, AWS EC2 y AWS Lambda.

El sistema se implementó de manera que el usuario pueda cargar un archivo CSV a través de la aplicación en Streamlit, y que este archivo se envíe a un bucket específico en el servicio AWS S3. Tal como se muestra en la Figura 16, cuando se carga un CSV en un bucket cuyo nombre está establecido en el código de la función Lambda, esta se activa automáticamente gracias a una configuración previa que permite la activación al detectar un nuevo CSV en el bucket. Esta función, a su vez, contiene instrucciones que, a medida que se ejecutan, generan salidas visibles en los logs mediante el uso del servicio de gestión y monitoreo AWS CloudWatch.

Figura 16

Arquitectura de Integración de AWS Lambda con S3 y CloudWatch



Por otro lado, como se ilustra en la Figura 17, se levantó una instancia en el servicio AWS EC2, la cual se utilizó para hospedar una aplicación en el entorno de desarrollo Flask. Esta

ventas. Esto es posible debido a que la instancia de EC2 donde se encuentra desarrollada la aplicación en Flask aloja los archivos con extensión .keras y .pkl, que se utilizan para cargar el modelo y realizar la inferencia con el dataset proporcionado por el usuario. Las predicciones resultantes se envían de vuelta a la aplicación en Streamlit, que también está alojada en una instancia diferente de EC2, permitiendo al usuario visualizar las gráficas generadas.

3.4 Resultados

Como resultado del proceso de entrenamiento del modelo LSTM multivariado y el desarrollo de una interfaz gráfica, se logró una combinación efectiva que permite tanto realizar predicciones precisas como presentarlas de manera visualmente accesible. Esta sinergia entre el modelo y la interfaz facilita no solo la obtención de proyecciones de ventas, sino también su interpretación y análisis. A continuación, se presentan tanto los resultados obtenidos en el modelo como las visualizaciones que los acompañan, destacando la integración de estas herramientas en el análisis de tendencias futuras.

3.4.1 Rendimiento del modelo

Para el entrenamiento del modelo se utilizaron técnicas para mejorar la estabilidad y generalización del modelo, como es la técnica de EarlyStopping que monitorea la pérdida del conjunto de validación que detiene el entrenamiento en caso de que no mejore, por ello se notará que hay diferentes épocas para cada producto, para evitar que el modelo siga ajustandose de manera innecesaria, también se utilizó reduceLRonPlateau que reduce la tasa de aprendizaje cuando la pérdida de validación deja de mejorar.

En general se muestra la evolución de la pérdida (RMSE) durante el entrenamiento y validación de diferentes configuraciones. Se ha utilizado una combinación combinación de ajustes como tasa de aprendizaje, regularización (KernelReg) y Dropout, en la mayoría de los casos el uso del dropout ha permitido ajustes más suaves, el rendimiento del modelo ha sido validado comparando las predicciones generadas para 4 días contra los datos reales, esto ha ayudado a

identificar cuáles son las configuraciones óptimas para cada producto, logrando que las predicciones de cada modelo se acerquen lo máximo posible a los valores reales.

Figura 19

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=13887

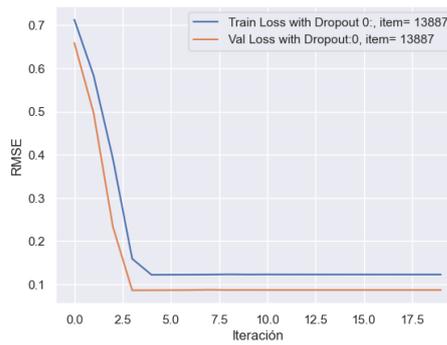


Figura 20

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=13887

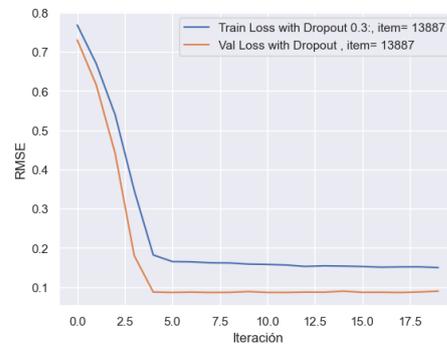


Figura 21

Comparación de datos reales con predicciones de diferentes configuraciones $id_item=13887$



Figura 22

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout $id_item=90765$

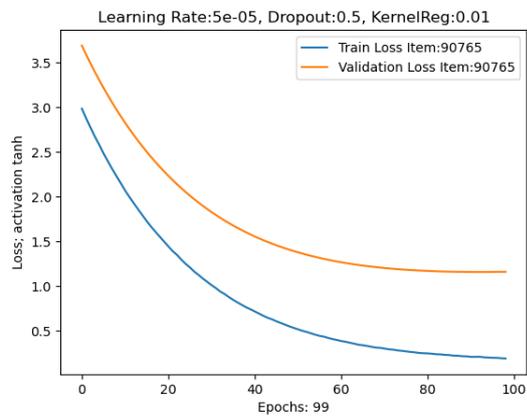


Figura 23

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout $id_item=90765$

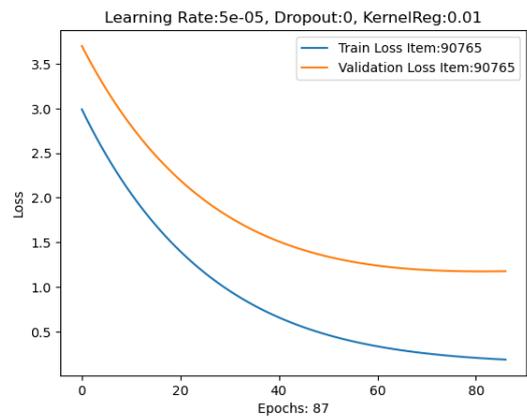


Figura 24

Comparación de datos reales con predicciones de diferentes configuraciones id_item=90765

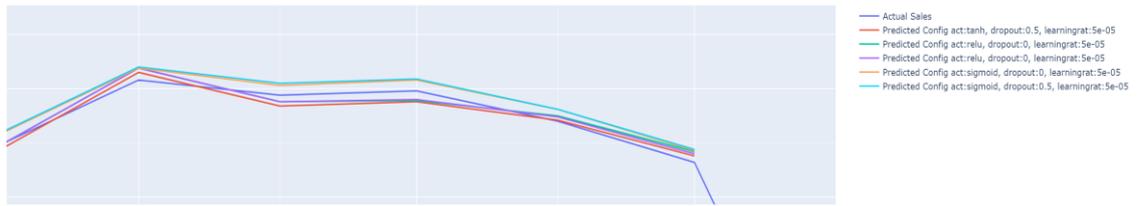


Figura 25

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=79680

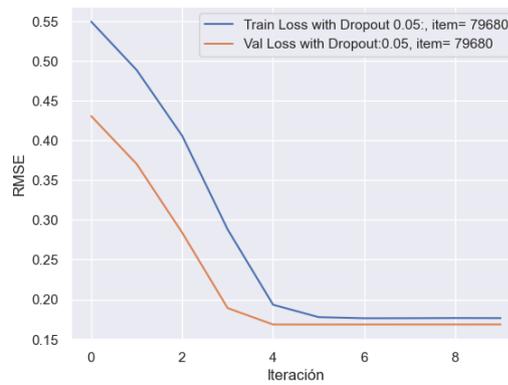


Figura 26

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=79680

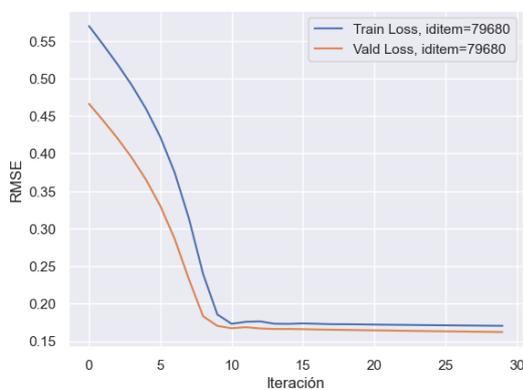


Figura 27

Comparación de datos reales con predicciones con diferentes configuraciones id_item=79680



Figura 28

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=27112

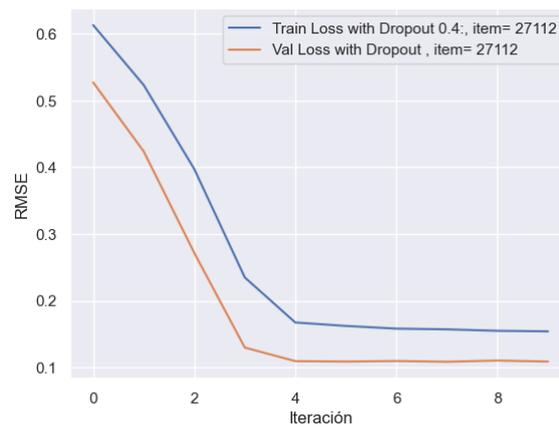


Figura 29

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=27112

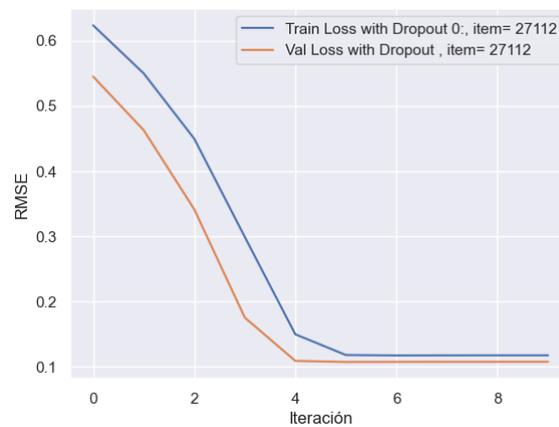


Figura 30

Comparación de datos reales con predicciones con diferentes configuraciones $id_item=27112$

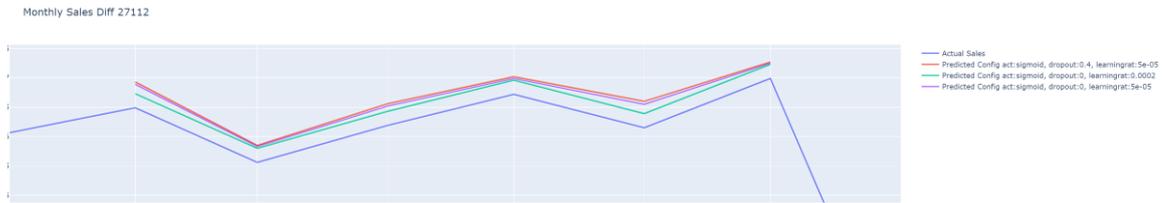


Figura 31

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout $id_item=1669$

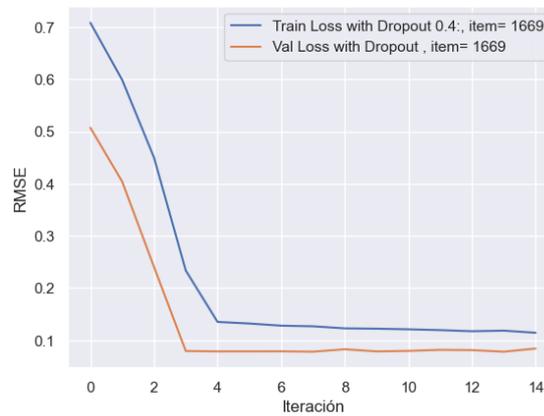


Figura 32

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout $id_item=1669$

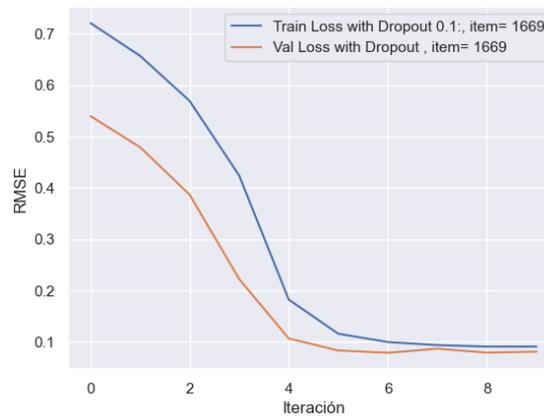


Figura 33

Comparación de datos reales con predicciones con diferentes configuraciones id_item=1669



Figura 34

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=101609

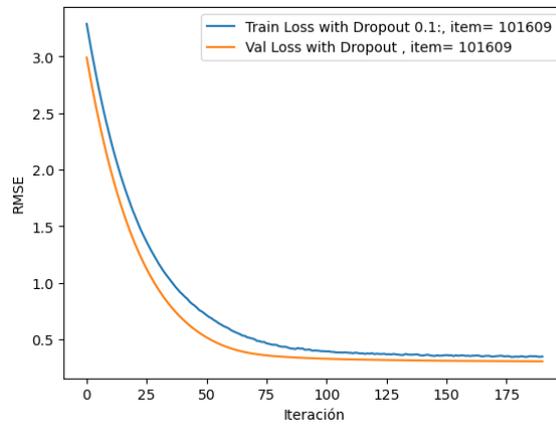


Figura 35

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=101609

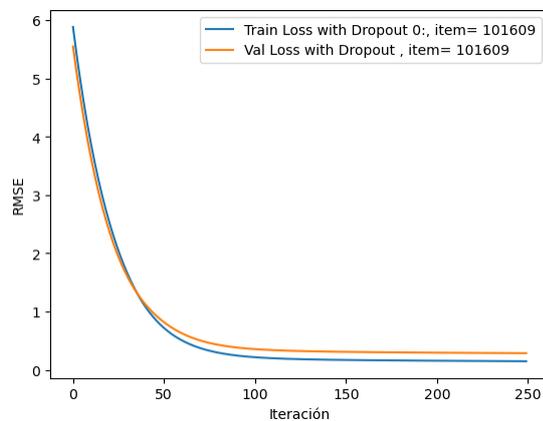


Figura 36

Comparación de datos reales con predicciones con diferentes configuraciones id_item=101609

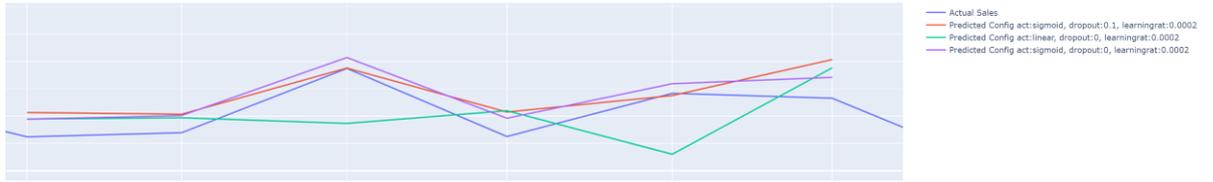


Figura 37

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=54122

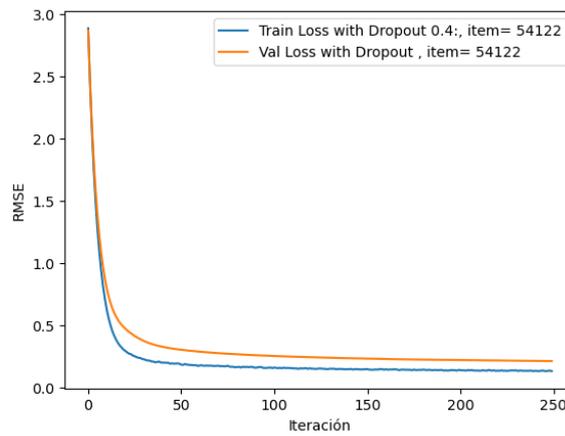


Figura 38

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=54122

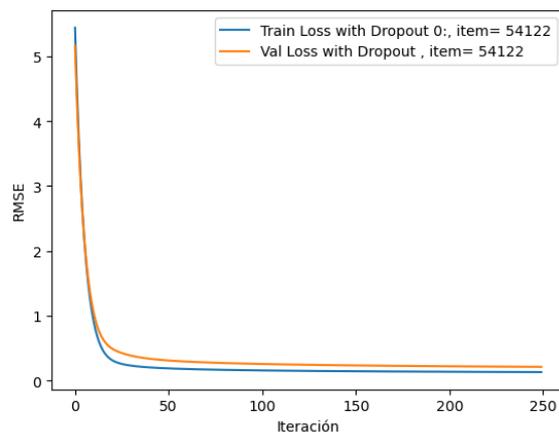


Figura 39

Comparación de datos reales con predicciones con diferentes configuraciones id_item=54122

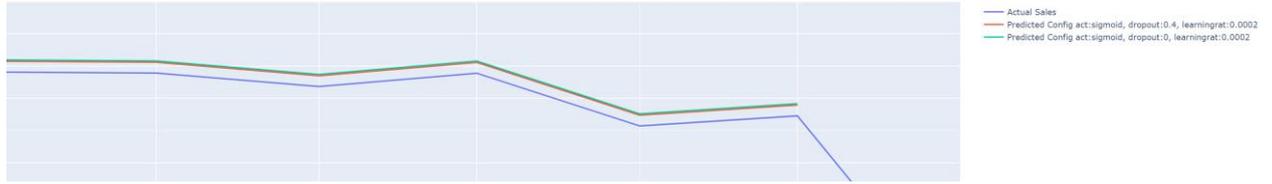


Figura 40

Gráfica de pérdida del conjunto de entrenamiento y validación sin dropout id_item=88275

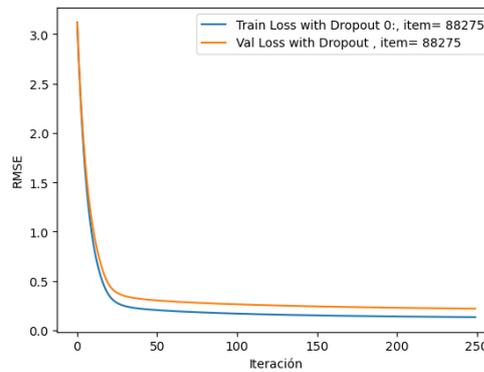


Figura 41

Gráfica de pérdida del conjunto de entrenamiento y validación con dropout id_item=88275

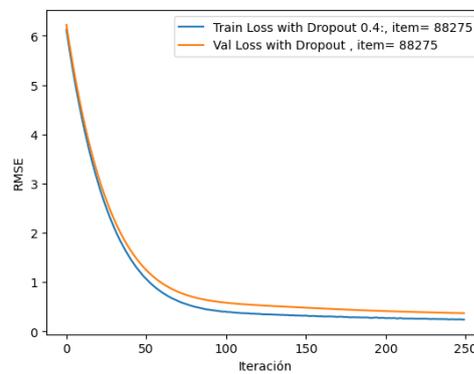


Figura 42

Comparación de datos reales con predicciones con diferentes configuraciones id_item=88275

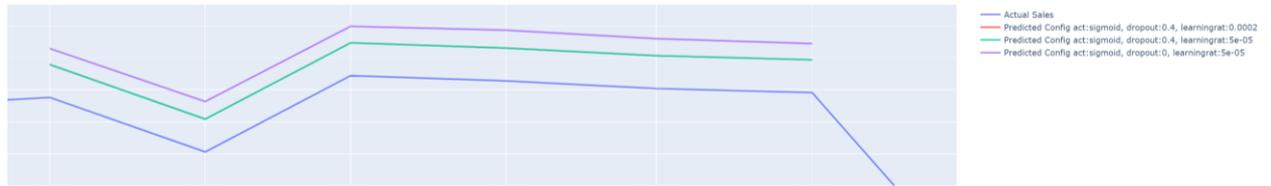


Tabla 6

Cuadro comparativo con los valores de RMSE de train, val, test

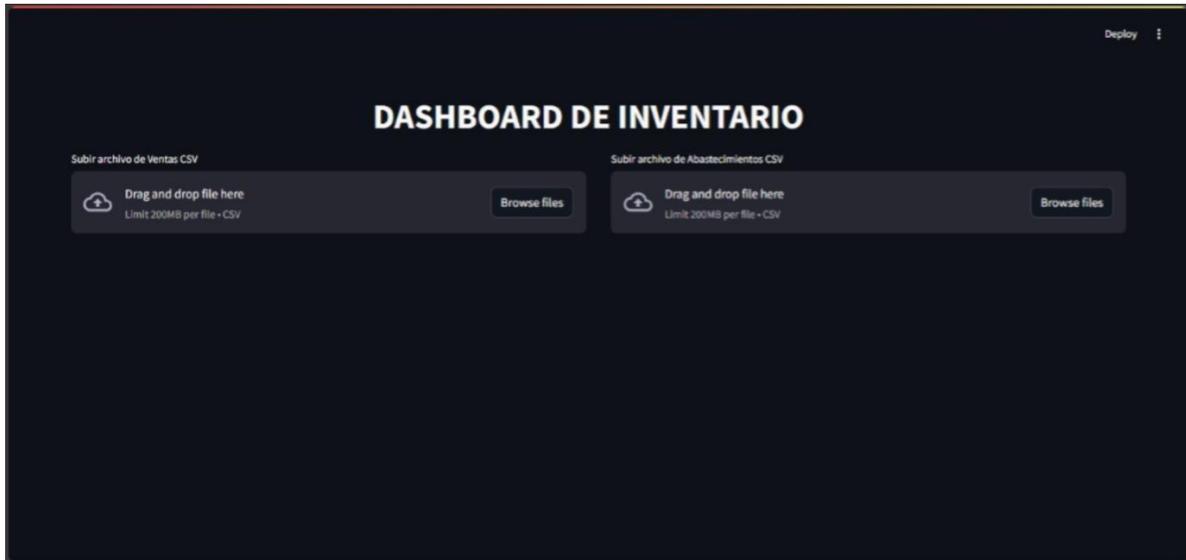
Item	RMSE train	RMSE val	RMSE test
88275	0.208	0.256	0.273
54122	0.167	0.265	0.347
101609	0.051	0.030	0.019
1669	0.099	0.103	0.119
27112	0.177	0.151	0.142
79680	0.239	0.225	0.223
90765	0.223	0.158	0.142
13887	0.114	0.086	0.107

3.4.2 Visualización interfaz gráfica

En la interfaz mostrada en la Figura 43 se observa el primer vistazo al dashboard, dentro del cual hay dos áreas principales para subir archivos CSV: uno para las ventas y otro para los abastecimientos. Cada uno tiene la opción de arrastrar y soltar archivos o buscar archivos en el sistema. Los archivos subidos se muestran con su nombre, tamaño y la opción de eliminarlos.

Figura 43

Vista de carga de archivos dashboard



Una vez que los archivos se han subido con éxito, se muestra una notificación de carga exitosa en la parte posterior, y luego se procede con el análisis y la visualización de los datos. Tal como se aprecia en la Figura 44, en el centro de la interfaz, se muestra un mapa interactivo de Ecuador, donde se visualizan las cantidades de ventas por ubicación geográfica. A la izquierda del mapa, se encuentran los indicadores de desempeño, que muestran información clave como las ventas de la semana actual, la comparación con las ventas de la semana anterior, y datos similares para los abastecimientos. Estos indicadores permiten visualizar rápidamente el rendimiento actual y las tendencias en comparación con periodos anteriores,

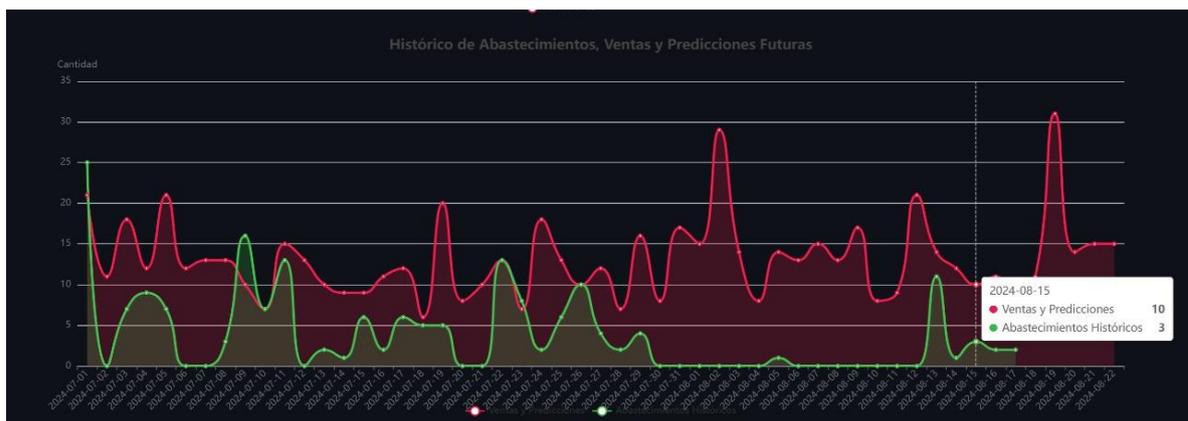
Por otro lado, a la derecha del mapa, hay un listado de las Top 10 Provincias por Cantidad, donde se visualizan las provincias con mayor número de ventas, este listado se muestra con barras horizontales rojas que facilitan la comparación visual de las cantidades entre las provincias.

De la misma forma, se puede apreciar en la parte izquierda del dashboard un sidebar en donde el usuario podrá aplicar los filtros tanto de producto como de fecha, así como también podrá cambiar el tema de la paleta de colores del dashboard.

De la misma manera, tal como se puede observar en el gráfico de la Figura 46, se presenta una serie temporal que consolida de manera efectiva la información sobre ventas, abastecimientos y predicciones. Este gráfico ofrece una representación visual del comportamiento histórico, donde se destacan las fluctuaciones de ventas y abastecimientos a lo largo del tiempo. Al final de la serie, se muestran las predicciones correspondientes a los cuatro días siguientes al último registro de ventas, lo que permite analizar el posible comportamiento futuro basado en los patrones observados.

Figura 46

Gráfico histórico de abastecimientos, ventas y predicciones futuras



3.4.3 Pruebas de validación

Como se puede apreciar en la Tabla 7, se realizaron diversas pruebas de validación en colaboración con el cliente y los usuarios finales de la empresa. Estas pruebas aseguraron que cada funcionalidad del sistema funcionara según lo esperado y cubriera las necesidades operativas del cliente. En primer lugar, se verificó la correcta carga de los archivos de ventas y abastecimiento, garantizando que los datos se cargan de manera precisa. Luego, se comprobó que la visualización de los gráficos se realiza en la ubicación correcta y con la información adecuada, cumpliendo con los requisitos establecidos por los usuarios. Finalmente, se validó que los filtros de fecha y producto aplican correctamente, actualizando los gráficos de forma rápida y eficaz, lo cual fue confirmado por los usuarios en su entorno de trabajo.

Tabla 7*Pruebas de validación*

Funcionalidad	Resultado esperado	Resultado real
Carga de archivos	Archivos cargados correctamente	Archivos de venta y abastecimiento cargados correctamente
Filtros de fecha y producto	Gráficos actualizados correctamente	Filtros aplicados en 5 segundos
Visualización de gráficos	Gráficos mostrados correctamente	Visualización correcta, gráficos mostrados en la ubicación donde corresponden

Como se detalla en la Tabla 8, las pruebas de rendimiento mostraron resultados satisfactorios en términos de tiempos de respuesta y capacidad del sistema. La carga de archivos mostró un tiempo promedio de 2.3 segundos, lo cual es eficiente para los archivos de tamaño pequeño y mediano.

En cuanto al procesamiento de ventas, para archivos de 1MB y 20MB, las predicciones fueron generadas correctamente en 4.64 y 19.93 segundos, respectivamente. Estos tiempos incluyen el viaje completo de los datos a través de Streamlit hacia los servicios de AWS, es decir, la interacción con Lambda, S3 y Flask. Todo este proceso, que implica la recepción, procesamiento y retorno de las predicciones, se completó en tiempos razonables, permitiendo que las gráficas se muestren de forma adecuada y sin interrupciones.

Finalmente, la prueba de carga simultánea con 10 usuarios confirmó que el sistema puede manejar múltiples solicitudes sin degradación significativa en el rendimiento. Aunque es cierto que a medida que aumenta la cantidad de usuarios el tiempo de respuesta podría incrementarse ligeramente, se comprobó que la funcionalidad del sistema no se ve comprometida, garantizando una experiencia fluida y estable para los usuarios.

Tabla 8*Pruebas de Rendimiento*

Prueba de rendimiento	Resultado esperado	Resultado real
Carga de archivos	< 5 segundos	4.5 segundos
Procesamiento de ventas para archivos de 1MB	Predicciones generadas correctamente	Generadas en 4.64 segundos
Procesamiento de ventas para archivos de 20MB	Predicciones generadas correctamente	Generadas en 19.93 segundos
Carga simultánea (10 usuarios)	Sin degradación	Correcto

Como se aprecia en la Tabla 9, además de las pruebas de rendimiento enfocadas en tiempos de respuesta, se realizaron pruebas relacionadas con la gestión de errores y la estabilidad del sistema. En primer lugar, se verificó la respuesta del sistema ante archivos inválidos. Como era esperado, el sistema mostró un error adecuado y evitó el procesamiento de dichos archivos, lo que garantiza la integridad de los datos y evita posibles fallos.

Asimismo, se evaluó la recuperación tras un fallo de red, simulando interrupciones temporales en la conexión. El sistema se recuperó sin problemas, permitiendo continuar con el flujo de trabajo sin pérdida de datos ni impacto en la experiencia del usuario. Esto demuestra la robustez del sistema frente a problemas temporales de conectividad, un aspecto esencial para garantizar la continuidad del servicio.

Tabla 9*Pruebas de Robustez*

Prueba de rendimiento	Resultado esperado	Resultado real
Archivos inválidos	Mostrar error y no procesar	Error mostrado
Recuperación tras fallo de red	Sistema debe recuperarse	Recuperado sin problemas

En la Tabla 10 se aprecian las principales variables utilizadas para medir la facilidad de uso del sistema. Estas métricas incluyen aspectos clave como la interactividad, la accesibilidad, el tiempo de respuesta, la simplicidad en la navegación, la tasa de errores, y la satisfacción general del usuario. Estas medidas permiten evaluar si el diseño del dashboard cumple con los requisitos de usabilidad y proporciona una experiencia eficiente y sencilla para los usuarios finales.

Tabla 10

Métricas de rendimiento para evaluar la intuitividad del dashboard

Métricas	Descripción
Interactividad y accesibilidad	Facilidad de uso y accesibilidad para usuarios sin habilidades técnicas.
Recuperación tras fallo de red	Tiempo requerido para aplicar filtros y visualizar datos.
Simplicidad de navegación	Cantidad de clics necesarios para acceder a funcionalidades clave.
Tasa de errores	Cantidad de errores cometidos por los usuarios al realizar tareas.
Satisfacción del usuario	Opinión general de los usuarios sobre la facilidad de uso del dashboard.

Capítulo 4

4.1 Conclusiones y recomendaciones

En esta sección se presentan las conclusiones clave derivadas del desarrollo y la implementación del sistema predictivo de ventas, así como las recomendaciones para futuras mejoras y estudios adicionales. Las conclusiones destacan los logros obtenidos, incluyendo la precisión en las predicciones y la efectividad del dashboard interactivo desarrollado. Por otro lado, las recomendaciones proporcionan directrices para optimizar aún más el sistema, explorar nuevas funcionalidades y ampliar el alcance del estudio para maximizar su aplicabilidad y rendimiento en entornos más complejos.

4.1.1 Conclusiones

Tras aplicar las fases necesarias de la propuesta se obtienen las siguientes conclusiones primordiales:

- El desarrollo del sistema de análisis predictivo basado en un modelo LSTM permitió realizar predicciones de las ventas de los diez productos seleccionados.
- Se logró implementar un algoritmo de predicción, capaz de manejar grandes volúmenes de datos. Esto asegura que el sistema pueda escalar y seguir proporcionando resultados incluso con un aumento en la cantidad de datos.
- Se desarrolló un dashboard interactivo en Streamlit que presenta los pronósticos de ventas mediante gráficos estadísticos, mapas de calor, y filtros personalizables. Este diseño mejora significativamente la experiencia del usuario, facilitando la interpretación y análisis de los datos.

4.1.2 Recomendaciones

Tras la culminación de las actividades planificadas en la propuesta, se derivan las siguientes recomendaciones clave para futuras investigaciones y desarrollos. Estas sugerencias

están orientadas a ampliar y mejorar los resultados obtenidos, así como a abordar las limitaciones encontradas durante el estudio.

- Se sugiere investigar y desarrollar funcionalidades adicionales en la plataforma Streamlit para mejorar la interactividad y personalización de las aplicaciones web. Esto podría incluir la integración de nuevas bibliotecas o el desarrollo de componentes personalizados.
- Se recomienda llevar a cabo estudios adicionales para optimizar el rendimiento de la aplicación, especialmente en entornos de gran escala o con volúmenes de datos significativos. La investigación futura podría centrarse en técnicas de escalabilidad y en la utilización más eficiente de los recursos en AWS.
- Considerando las limitaciones del presente trabajo, se sugiere ampliar el alcance del estudio incorporando más variables y características en los modelos LSTM, lo que podría proporcionar predicciones más precisas y robustas. Además, la inclusión de datos en tiempo real podría mejorar la relevancia y aplicabilidad de los resultados.

REFERENCIAS

- [1] J. J. Mora Román y F. Carvajal Rodríguez, Medicamentos no utilizables: problemática y medidas pertinentes para su disposición final, vol. 10, 2016, pp. 27-36.
- [2] J. C. Fiallos, C. Mena y M. J. Robles, «RFID technology in healthcare: A study of pharmaceutical inventory management,» International Journal of Production Economics, vol. 215, pp. 43-53, 2019.
- [3] J. Mendes, A. Amaral y V. Cruz Machado, «A systematic literature review on applications of artificial intelligence and big data analytics for supply chain inventory management,» International Journal of Production Research, vol. 58, n° 8, pp. 2498-2522, 2020.
- [4] S. L. Kakade y L. Vitalkar, «Inventory management in pharmaceutical industry,» International Journal of Scientific Research in Engineering and Management, vol. 8, p. 6, 2024.
- [5] J. Laínez, E. Schaefer y G. Reklaitis, «Challenges and opportunities in enterprisewide optimization in the pharmaceutical industry,» Computers & Chemical Engineering, vol. 47, pp. 19-28, 2012.
- [6] A. Andrews y N. Nishkar, «Decoding financial performance of US-listed entities: A sectoral study,» Finance Research Letters, vol. 64, p. 6, 2024.
- [7] J. Huang y D. Yun, Journal of Physics: Conference Series, vol. 1756, n° 1, 2021.
- [8] A. Moghar y M. Hamiche, Stock market prediction using LSTM recurrent neural network, vol. 170, 2020, pp. 1168-1173.
- [9] C. Krauss y T. Fischer, «Deep learning with long short-term memory networks for financial market predictions,» European Journal of Operational Research, vol. 270, n° 2, pp. 654-669, 2018.
- [10] J. Yuan, C. Chen, W. Yang, M. Liu, J. Xia y S. Liu, «A survey of visual analytics techniques for machine learning,» Computational Visual Media, vol. 7, n° 1, pp. 3-36, 2021.
- [11] U. M. Castro Morales, «Prónóstico de ventas a corto plazo en el sector de consumo masivo A,» Bogotá, 2024.
- [12] W. E. Romero Pacheco y J. R. Vega Pérez, «Diseño e implementación de un sistema de registro de inventario para mejorar la gestión de un negocio.,» 2023.

- [13] G. García Espinosa, «Puesta en producción de modelos de aprendizaje automático y administración de su ciclo de vida (MLOps),» Cartagena, 2023.
- [14] J. M. Nápoles Duarte, A. Biswas, M. Parker, J. P. Palomares Baez, M. A. Chávez Rojo y L. M. Rodríguez Valdez, «Stmol: A component for building interactive molecular visualizations within streamlit web-applications,» *Frontiers in Molecular Biosciences*, vol. 9, 2022.
- [15] M. S. Kalluri y K. N. Karamtoti , «Network Congestion Visualization for Vehicular Communication using Streamlit Approach,» 2024.
- [16] P. Wankhede, M. Talati y R. Chinchamatpure, «Comparative study of cloud platforms- microsoft azure, google cloud platform and amazon EC2.,» *Journal of Research in Engineering and Applied Sciences*, vol. 5, n° 02, pp. 60-64, 2020.
- [17] M. Sajee y J. Varia, «Overview of Amazon Web Services,» *Amazon Whitepapers*, vol. 105, n° 1, p. 22, 2014.
- [18] O. O. Adebisi, «Exploring the Impact of Predictive Analytics on Accounting and Auditing Expertise: A Regression Analysis of LinkedIn Survey Data,» *Asian Journal of Economics Business and Accounting*, vol. 23, n° 22, pp. 286-305, 2023.
- [19] S. Wang, «Enhancing risk assessment accuracy with predictive analytics in risk management,» *Risk Analysis*, vol. 17, n° 2, pp. 145-159, 2021.
- [20] R. Thakker, «Identifying anomalies and warning signs with predictive analytics in auditing,» *Journal of Accounting Anomaly Detection*, vol. 14, n° 4, pp. 317-331, 2023.
- [21] G. Kocher y G. Kumar, «Machine learning and deep learning methods for intrusion detection systems: Recent developments and challenges,» *Soft Computing*, vol. 25, n° 2, pp. 9731-9763, 2021.
- [22] M. R. Khatri, «Integration of natural language processing, self-service platforms, predictive maintenance, and prescriptive analytics for cost reduction, personalization, and real-time insights in customer service and operational efficiency,» *International Journal of Information Cybersecurity*, vol. 7, n° 9, pp. 1-30, 2023.
- [23] R. Clarke, «Identifying and mitigating risks in the dynamic business landscape with predictive analytics,» *Risk Management*, vol. 19, n° 1, pp. 58-73, 2020.
- [24] O. O. Olagbaju y O. O. Olaniyi, «Explicit and differentiated phonics instruction on pupils' literacy skills in Gambian lower basic schools,» *Asian Journal of Education and Social Studies*, vol. 44, n° 2, pp. 20-30, 2023.

- [25] S. Hochreiter y J. Schmidhuber, «Long short-term memory,» *Neural computation*, vol. 9, n° 8, pp. 1735-1780, 1997.
- [26] Amazon Web Services, «Amazon S3,» [En línea]. Available: <https://aws.amazon.com/es/s3/>.
- [27] Amazon Web Services, «Precios de Amazon S3,» [En línea]. Available: <https://aws.amazon.com/es/s3/pricing/>.
- [28] Amazon Web Services, «AWS Lambda,» [En línea]. Available: <https://aws.amazon.com/lambda/>.
- [29] Amazon Web Services, «Precios de AWS Lambda,» [En línea]. Available: <https://aws.amazon.com/es/lambda/pricing/>.
- [30] Amazon Web Services, «Amazon EC2,» [En línea]. Available: <https://aws.amazon.com/es/ec2/>.
- [31] Amazon Web Services, «Precios de Amazon EC2,» [En línea]. Available: <https://aws.amazon.com/es/ec2/pricing/>.
- [32] J. López, «La transformada de Fourier: propiedades y aplicaciones,» [En línea]. Available: <https://www.ugr.es/~jllopez/assets/files/TFourier.pdf>.
- [33] M. Sotaquirá, «Pronósticos sobre Series de Tiempo con Redes LSTM - Parte 6: codificación de la variable temporal,» 16 octubre 2023 . [En línea]. Available: <https://www.codificandobits.com/tutorial/forecasting-redes-lstm-6-codificacion-variable-temporal/>.
- [34] J. Amat Rodrigo y J. Escobar Ortiz, «Skforecast: forecasting series temporales con Python, Machine Learning y Scikit-learn,» febrero 2021. [En línea]. Available: <https://cienciadedatos.net/documentos/py27-forecasting-series-temporales-python-scikitlearn.html>.