

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



**Desarrollo de una aplicación de predicción usando machine learning para
la planificación de compra de insumos en el restaurante El Nuevo
Ferrocarril**

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

AUTOR

Nelson Alonso Chiroque Huamanchumo

ASESOR

Karla Cecilia Reyes Burgos

<https://orcid.org/0000-0003-3520-5076>

Chiclayo, 2025

**Desarrollo de una aplicación de predicción usando machine learning
para la planificación de compra de insumos en el restaurante El
Nuevo Ferrocarril**

PRESENTADA POR

Nelson Alonso Chiroque Huamanchumo

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

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR

Huiler Juanito Mera Montenegro

PRESIDENTE

María Ysabel Arangurí García

SECRETARIO

Karla Cecilia Reyes Burgos

VOCAL

Dedicatoria

Este trabajo está dedicado a Dios, quien siempre está presente en cada momento de mi vida. Asimismo, a mi familia, quienes siempre han estado apoyándome a cumplir todas mis metas.

Agradecimientos

Expreso mi agradecimiento a mi asesor de tesis la Mgtr. Karla Cecilia Reyes Burgos, por su apoyo durante el desarrollo y finalización de la investigación.

Asimismo, a mis docentes de la facultad de Ingeniería quienes durante toda mi carrera me han ayudado a formarme como profesional.

Por último, pero no menos importante a la empresa El Nuevo Ferrocarril a través del administrador Brayan Esparza y la dueña Virginia Huamanchumo, por brindarme la información y el tiempo para llevar a cabo mi investigación.

Desarrollo de una aplicación de predicción usando machine learning para la planificación de compra de insumos en el restaurante El Nuevo Ferrocarril

INFORME DE ORIGINALIDAD

15%	14%	4%	6%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	tesis.usat.edu.pe Fuente de Internet	3%
2	hdl.handle.net Fuente de Internet	2%
3	www.coursehero.com Fuente de Internet	1%
4	www.proyectum.com Fuente de Internet	1%
5	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1%
6	Submitted to ufidelitas Trabajo del estudiante	<1%
7	ojs.unipamplona.edu.co Fuente de Internet	<1%
8	Submitted to Universita' La Sapienza Trabajo del estudiante	<1%
9	thesai.org Fuente de Internet	<1%
10	repositorio.upn.edu.pe Fuente de Internet	<1%
11	Submitted to University of Hertfordshire Trabajo del estudiante	<1%

Índice

Resumen	6
Abstract	7
Introducción	8
Revisión de la literatura.....	10
Restauración.....	13
Demanda	13
Planificación de compras	13
Gestión de stocks.....	14
Series temporales	15
Pronósticos de ventas	15
Machine Learning	15
Modelos de predicción	15
Métricas de evaluación de pronóstico	16
Aplicación web.....	16
Materiales y métodos	17
Resultados y discusión	17
Resultados	17
Discusión.....	36
Conclusiones	37
Recomendaciones.....	38
Referencias	38
Anexos.....	42

Resumen

La investigación aborda el problema de planificación de compra de insumos en el restaurante El Nuevo Ferrocarril, debido a que la cantidad de compras era calculada basándose únicamente en la experiencia de ventas pasadas, generando gastos por sobreabastecimiento o desabastecimiento de insumos. Ante ello se desarrolló una aplicación web que utiliza un modelo de predicción de ventas basado en ML, para determinar la cantidad de insumos a comprar. Con el fin de lograr nuestro objetivo principal, se evaluaron los modelos ARIMA, Random Forest, Prophet y RNN LSTM con MAPE y MSE, usando 157 registros de ventas semanales y considerando análisis de series temporal y la inclusión de días festivos. También, se valoró la precisión de los modelos predictivos por cada producto, usando la métrica FA. Finalmente se evaluó la calidad de la aplicación web usando la métrica "rendimiento" y la herramienta Lighthouse. Los resultados obtenidos seleccionaron a Prophet como el mejor modelo con 537.36 de MSE promedio y 14.16% de MAPE promedio. Se obtuvo una alta precisión por cada modelo, con un FA promedio de 0.71. La calidad de la aplicación registró un rendimiento medio de 90, indicándonos una buena calidad de la aplicación. El proyecto fue desarrollado usando SCRUM por su adaptabilidad en los requerimientos y entregables en corto plazo, además, la aplicación fue desarrollada usando el framework Flask, FastApi y el lenguaje Python.

Palabras clave: Predicción de ventas, Planificación de compra de insumos, ARIMA, Random Forest, Modelo prophet, RNN-LSTM

Abstract

The research addresses the problem of planning the purchase of inputs in the restaurant El Nuevo Ferrocarril, because the amount of purchases was calculated based solely on the experience of past sales, generating expenses due to oversupply or shortage of inputs. Therefore, a web application was developed that uses a sales prediction model based on ML to determine the amount of inputs to be purchased. In order to achieve our main objective, ARIMA, Random Forest, Prophet and RNN LSTM models were evaluated with MAPE and MSE, using 157 weekly sales records and considering time series analysis and the inclusion of holidays. Also, the accuracy of the predictive models was assessed for each product, using the FA metric. Finally, the quality of the web application was evaluated using the “performance” metric and the Lighthouse tool. The results obtained selected Prophet as the best model with 537.36 average MSE and 14.16% average MAPE. High accuracy was obtained for each model, with an average FA of 0.71. The quality of the application recorded an average performance of 90, indicating a good quality of the application. The project was developed using SCRUM for its adaptability in the requirements and deliverables in a short period of time, in addition, the application was developed using the Flask framework, FastApi and the Python language.

Keywords: Sales prediction, Input purchase planning, ARIMA, Random Forest, Prophet model, RNN-LSTM

Introducción

Los restaurantes son espacios comerciales en los que se paga por el consumo de alimentos y bebidas ya sea dentro o fuera de él [1]. Este tipo de negocios generan utilidades a partir de una adecuada administración del restaurante [2]. Por el contrario, una inadecuada planificación puede ocasionar un cálculo errado en el presupuesto de inversión, los costos futuros (costo promedio del producto, costo por gastos, entre otros) y el número de ventas [2]. Esto puede llegar a ocasionar deficiencias o excesos en alimentos necesarios que perjudican al restaurante y a los índices de desperdicio de alimentos generados por el sector de servicio de comidas.

La investigación del marco de proyecto europeo FUSIONS (Innovation by Optimising Waste Prevention Strategies) determinó que una de las causas del exceso de alimentos preparados, en el sector de servicio de comidas, es la elaboración de pronósticos incorrectos en la cantidad de porciones a preparar, ocasionando pérdidas por vencimiento de productos desechados [3]. Según la ONU, a nivel mundial el sector de servicio de alimentos representa el 26% del total de desperdicio de alimentos, por otra parte, a nivel de Latinoamérica la FAO (Organización de las Naciones Unidas para la Alimentación y la Agricultura) afirma que en el año 2019 el continente fue responsable del 20% del desperdicio de alimentos [3].

Los problemas de planificación de compras en restaurantes han sido estudiados en investigaciones internacionales como la de Bharucha [4], [5], determinando que de 63 restaurantes de la India el 75% de estos generaba alimentos en exceso y solo el 30% de ellos lo reutilizaban, siendo esto causado por el cálculo de productos adicionales basado en la experiencia de ventas pasadas. A nivel nacional Camac [5] investiga los problemas en una cevichería determinando que el 43% de las incidencias era por costos elevados en compra de materia prima inmediata, ocasionando gastos en materia prima de 27 908.96 soles. Por otra parte, a nivel regional Bernabe [6] realiza una investigación a 25 MYPES del sector gastronómico, determinando que el 64% de las empresas define las cantidades de compra basándose en las ventas de las semanas anteriores, además, del 56 % del promedio de pérdidas el 10 % se debía a mermas en sus suministros.

Ante el panorama global descrito, es crucial comprender esta problemática en un ámbito específico, por ello se realizó esta investigación en la empresa El Nuevo Ferrocarril. Esta empresa del rubro de restaurantes brinda el servicio de venta de productos típicos norteños, se ubica en el distrito de Puerto Eten y basa su oferta gastronómica, principalmente, en la preparación de productos marinos y comida criolla, la cual es modificada cada seis meses para adecuarse a las nuevas tendencias culinarias, ofertas de la zona y abastecimiento de insumos, siendo este último, un factor importante pues, durante el año existen variabilidad de insumos

por temporada, como el cabrito, pescados, marisco o verduras que tienen una oferta irregular en el mercado tanto en cantidad como en precio, generando incertidumbre y apresuramiento en su abastecimiento.

El administrador y el jefe de cocina planean la compra de insumos, estimando la cantidad de insumos a comprar según la experiencia de ventas pasadas. Esta estimación es empleada en el proceso de preparación de alimentos, ya que en base a esta se realiza la preparación de productos anticipados tanto para aquellos que complementan al producto principal, como, por ejemplo: camote o choclo sancochado, etc, así como para los productos que llevan un tiempo de preparación largo como: el cabrito, arroz con mariscos, tortitas de choclo, entre otros, generando estimaciones no acordes con la demanda real, donde el promedio de precisión de los pronósticos empíricos era 49, es decir los pronósticos en términos porcentuales no llegaban al 50% de precisión (ver Anexo I). Esto generaba costos de oportunidad en ganancias por ventas, pues los insumos comprados son insuficientes para abastecer a la demanda solicitada y a su vez conlleva gastos por sobrecostos al realizar un promedio de 23 veces al mes compras improvisadas a proveedores minoristas (bodegas y mercados cercanos). También, se dieron casos en los que la demanda real era menor a la demanda esperada, generando gastos por sobreabastecimiento de insumos, en los que el 40 % de los insumos en exceso eran desechados o regalados, por caducidad (ver Anexo II y III). Estos problemas agravan su situación económica ya que, se suman a la disminución del porcentaje de ventas encontrado entre los años 2017 al 2023, en el cual se identificó una disminución del porcentaje de ventas en un 8.02% en el último (ver Anexo III), infiriendo que, de continuar con la mala planificación de las compras en el restaurante, se generarían mayores pérdidas tanto por sobreabastecimiento o desabastecimiento de insumos afectando las ganancias de la empresa.

Ante la problemática anteriormente descrita se planteó la siguiente pregunta de investigación ¿Cómo se puede predecir la cantidad de insumos a comprar en el proceso de planificación de compra del restaurante El Nuevo Ferrocarril? Es así que la investigación se justifica de forma científica como aporte a futuros investigadores en el desarrollo de una solución para mejorar la toma de decisiones en planificación de compras, mediante una aplicación tecnológica predictiva para restaurantes. Como justificación económica, la investigación permitió que la empresa pueda corregir la toma de decisiones en costos por planificación de compras, lo cual puede generar pérdidas por una mala estimación de insumos necesarios, además del costo por mermas y sobreproducción de comida. Se justifica de forma social ya que, la solución se aplicó a una empresa del subsector de restaurantes contribuye al crecimiento del PBI nacional, mediante la obtención de mejores resultados en sus ventas. Finalmente, la justificación tecnológica está en

una solución que emplea una aplicación web junto con ML (Aprendizaje Automático - Machine Learning), permitiendo calcular el total de insumos a comprar mediante la predicción de ventas, usando los datos históricos.

Como solución a la problemática planteada se consideró el uso de ML, el cual emplea técnicas estadísticas y algoritmos computacionales para realizar tareas de predicción [7]. Por ello se desarrolló una aplicación web basada en un modelo de predicción de ventas usando ML, que se usó para calcular la cantidad de insumos que se necesitarán comprar. Se planteó como objetivo principal desarrollar una aplicación de predicción basada en ML para apoyar la planificación de compra de insumos en el restaurante El Nuevo Ferrocarril. Como objetivos específicos se definió la selección del mejor modelo de predicción de ML para obtener predicciones de ventas, una alta valoración en la precisión de los modelos predictivos para su implementación en una aplicación web y, por último, evaluar la calidad de la aplicación para su adecuado desempeño.

Revisión de la literatura

En esta sección se revisaron los antecedentes y fundamentos teóricos que sustentan la investigación. A continuación, se detallan los nueve antecedentes seleccionados:

Feizabadi [8] investigó la previsión de la demanda en la cadena de suministro de una empresa siderúrgica, que usaba modelos tradicionales para predecir ventas futuras, pero enfrentaba problemas de predicciones distorsionadas generando compras ineficientes. Ante ello se desarrolló un modelo híbrido de predicción combinando Media Móvil Integrado Autorregresiva con variables exógenas (ARIMAX) y Redes Neuronales prealimentadas (NN) basado en ML (Aprendizaje Automático - Machine Learning) y análisis de series temporales; para ello se buscó determinar la influencia de rendimiento de la cadena de suministro. Los resultados de precisión del modelo se calcularon por el indicador FA (Precisión de pronóstico - Forest Accuracy) obteniendo un 5% más de precisión en comparación con los modelos tradicionales. Además, el impacto del modelo en la cadena de suministro mostró una mejora significativa. La investigación aportó el conocimiento teórico del uso de modelos de ML con series temporales, e indicadores de precisión de predicción como FA.

Chalán [9], aborda los problemas en los procesos de abastecimiento para la cadena de restaurantes ubicada en Guayaquil Ecuador, identificando inventarios con falta y exceso de suministros, ausencia de procesos planificados, entre otros, ocasionando pérdidas por materias primas vencidas. Por ello plantea un análisis de los procesos de la empresa y elaboración de estrategias que mejoren la logística de abastecimiento. La investigación empleó entrevistas para

la recolección de datos y análisis de Ishikawa para identificar las causas del problema. Los resultados determinaron que la planificación de compras empleaba una proyección de consumo impreciso basada en el consumo promedio semanal o mensual de los restaurantes, además planteando la implementación de un sistema ERP Oracle para gestión de compras, además de medir eficiencia, eficacia y rotación del inventario. Esta investigación aportó como base teórica de los procesos de planificación de compras y abastecimiento de inventario, además, de la aplicación de instrumentos de recolección de datos para conocer los procesos de la empresa.

Nassibi et al.[10] y Camac[5] realizan su investigación en una empresa del rubro restaurantes y una empresa de venta de productos alimenticios respectivamente. Identificando problemas de planificación de compras y gestión de inventarios. [10] determinó que esto se debía a pronósticos de ventas inexactos que ocasionaban gastos por almacenamiento y desecho de materias primas, mientras que [5] determinó que la causa se debía a la planificación de compras lo cual causaba sobrecostos en la compra de materia prima. Ambas investigaciones realizan la implementación de un modelo de predicción de ventas para calcular la cantidad a comprar. Para ello [10], evaluó dos modelos de predicción: SVM (Máquina de Vectores de Soporte - Support Vector Machine) y RNN LSTM (Redes Neuronales con Memoria a Corto Plazo - Neural Network LSTM), usando las métricas de precisión MAPE y RMSE, considerando la influencia de dos factores externos: la sede y el canal de distribución (venta mayorista, minorista, etc.). Por otra parte, [5] empleó el método de suavizado exponencial para desarrollar su modelo de predicción. Los resultados obtenidos por [10] muestran que LSTM fue el mejor, con reducción del error del 77% en comparación SVM. Por su parte [5] concluyó que la solución implementada redujo un 7,77 % el costo por compra de materias primas. Estas investigaciones se consideraron por su aporte en la selección del mejor modelo de predicción usando métricas de precisión y considerando la influencia de factores externo.

Nima et al. [11] y Custodio [12] realizaron investigaciones sobre problemas de planificación de compras y gestión de inventarios en una empresa retail y una empresa alimentaria respectivamente. Ambas investigaciones identificaron que la causa del problema era el uso de pronósticos de ventas imprecisos basados en la experiencia de ventas pasadas, ocasionando pérdidas de dinero por exceso o deficiencia de insumos comprados. Ante ello, [11] desarrolló estrategias de reducción de stock junto con un modelo de predicción de ventas, mientras que [12] desarrolló un sistema gestor de inventarios basado en un modelo de predicción de ventas. Para lograr esto, [11] emplea análisis multicriterio ABC con Cycle counting, para categorizar los productos por frecuencia de compra, seleccionando el método de pronóstico más preciso al evaluar los métodos: Promedio móvil, Suavización exponencial doble, Regresión lineal y

Atenuación exponencial, usando MAPE. Por otra parte [12] seleccionó el mejor método de pronóstico entre promedio móvil simple, promedio móvil ponderado y regresión lineal, usando MAPE, para ocho productos. Los resultados de [11] lograron un MAPE promedio de 9,63 y reducción del error de predicción en un 13,05 %. Por otra parte, [12] obtuvo una disminución del 46.93% del MAPE medio para los métodos de predicción. Estas investigaciones fueron seleccionadas por emplear indicadores como quiebre de stock y MAPE para medir el cumplimiento de sus objetivos.

Farroñan [13], aborda el problema de una inadecuada gestión de compras e inventarios, debido a la toma de decisiones en base a proyecciones de ventas imprecisas, basadas en información de ventas pasadas, ocasionando pérdidas por tratamiento de productos vencidos. Para ello se desarrolló un sistema de proyección de ventas a través de un datamart, empleando la metodología de desarrollo CRISP-DM y un modelo de regresión para la proyección de ventas, obteniendo como resultados el incremento de los reportes de alerta de artículos por vencer a dos y el cumplimiento de las metas en un 95%. La investigación se consideró porque aborda el problema de gestión de compras mediante proyecciones de ventas, siguiendo un proceso similar al usado en la investigación.

SantaCruz [14], aborda el problema de gestión de inventarios en la empresa concesionaria “Motofuerza S.A.C”, debido a la ausencia de información actualizada sobre su stock y pronósticos de ventas imprecisos, ocasionando disminución de ventas y pérdidas monetarias. Ante ello se desarrolla un sistema de BI con predicción de ventas y series temporales. Para ello se empleó la metodología híbrida Ralph Kimball y Crisp DM, para la parte de BI y Minería de datos, además se evaluó el mejor algoritmo de predicción de series temporales entre ARIMA, ARTXP y MIXED. Los resultados seleccionaron a ARTXP con un MAPE de 62%, además, el sistema de BI logró implementación de 8 reportes para predicción de productos y análisis de ventas. Esta investigación se seleccionó por emplear la métrica MAPE para seleccionar la técnica de predicción, detallar el proceso de limpieza de la información y presentar el resultado de la predicción de ventas en reportes

Vilchez [15], aborda los problemas de una inadecuada planificación de inventarios en una farmacia, debido a que la planificación se realizaba sin considerar el stock actual, ocasionando abastecimiento y un desabastecimiento de stock y pérdidas en ventas. Ante ello se desarrolla una aplicación web de pronósticos para la demanda, usando redes neuronales y CRISP-DM. Los resultados muestran que la aplicación obtuvo 92 puntos en rendimiento (empleando lighthouse), además de un promedio de 0,9 en los modelos generados para la métrica R-Cuadrado y un MAPE de 17,88 %, lo que indica un modelo con alta precisión. Este trabajo

servió como guía para el desarrollo de una solución web que emplea modelos de pronósticos de demanda y mide su calidad usando rendimiento.

A continuación, se expondrán los fundamentos teóricos que sustentan el desarrollo de esta investigación:

Restauración

Es la acción de comer para alimentarse y restaurar energías [16]. Este es un término relacionado con negocios del servicio gastronómico [16]. En la investigación, este término fue referido al servicio de venta bebidas y comida de tipo criolla y marina, que ofrece la empresa.

Demanda

Empleado para referirse al número de veces que un producto o servicio se adquiere en un determinado momento [15]. En la investigación la demanda representaba el número de ventas de los productos en el tiempo y fue empleada en el análisis de ventas para obtener una proyección de ventas futuras, con la cual se determinó la cantidad de insumos a comprar.

Planificación de compras

Indica las necesidades de la organización, especificando lo que necesita, la cantidad y el momento, en un determinado periodo [17]. Este proceso abarca tres etapas: levantamiento de requerimientos, programación de compras y seguimiento de las compras [17]

Levantamiento de requerimientos

En esta etapa se determina que, y cuanto se necesitará comprar en el periodo de planificación, basándose en una proyección futura obtenida generalmente del histórico de la empresa [17]. En la empresa esta etapa se realizaba a través de proyecciones erradas basadas en la experiencia de ventas pasadas. Esta etapa se desarrolló en la aplicación web mediante la identificación de insumos a reponer basándose en las predicciones de ventas.

Programación de compras

Esta etapa define los recursos y mecanismos necesarios para la adquisición de los bienes identificados en la fase previa [17]. Esta etapa implica una interacción directa con el proveedor, pues toma en cuenta los requisitos de compra para seleccionar proveedores [17]. En la aplicación web se tuvo en cuenta esta etapa, mostrándole al usuario la información sobre el proveedor que pueda abastecerlo de aquellos insumos que requieran reposición.

Seguimiento de compras

En esta etapa se revisa el funcionamiento del plan de compras para corregir errores futuros [17]. En la empresa el seguimiento del plan de compras era realizado mediante un ajuste en la estimación de ventas empírica, por lo que no era significativo. La solución desarrollada

permitió poder ir mejorando la precisión del modelo de predicción, usando entrenamiento con ventas reales.

Gestión de stocks

Permite determinar las cantidades óptimas de insumos que la empresa debe disponer con el mínimo coste [18]. La solución desarrollada empleó dos indicadores de gestión de stock el stock máximo y el punto de pedido, para mostrar los insumos y las cantidades necesarias a comprar.

Stock de seguridad

Cantidad de respaldo de un insumo que es necesario mantener para cubrir situaciones no previstas [18]. Se calcula de la siguiente manera:

$$ss = Dd \cdot (dr - d)$$

Donde: “Dd” es demanda diaria, “dr” es tiempo de entrega con posibles días de retraso (para el proyecto se usó 3) y “d” es plazo de entrega en días.

Stock activo

Representa la cantidad de insumos necesaria para cubrir la demanda de productos normales [18]. Se calcula con la siguiente formula:

$$sa = Dd \cdot n$$

Donde: “Dd” es demanda diaria, “n” número de días de actividad del periodo

Stock máximo

Cantidad máxima de un insumo que conviene comprar para mantener la calidad del servicio con un menor costo [18]. Se calcula con la siguiente formula:

$$\begin{aligned} stockmax = (Stock\ activo + Stock\ previsto\ durante\ plazo\ de\ entrega \\ + Stock\ de\ seguridad) = sa + Dd \cdot d + ss \end{aligned}$$

Donde: ”sa” stock activo, “Dd” es demanda diaria, “d” plazo de entrega en días (para el proyecto se usó 1 día) y “ss” stock de seguridad.

Este indicador fue usado en la aplicación web, para determinar la cantidad máxima a comprar por cada insumo, evitando sobreabastecimiento y gastos innecesarios.

Punto de pedido

Indicador de mantenibilidad de stock, que determina la cantidad de unidades mínimas de un insumo en inventario para garantizar el cumplimiento de un pedido hasta la próxima compra [18]. Se calcula con la siguiente formula:

$$PP = Dd \cdot d + ss$$

Donde: “Dd” es Demanda diaria, “d” plazo de entrega en días y “ss” stock de seguridad.

En la aplicación web se usó este indicador para determinar los insumos que requieren reposición, ya que si el stock proyectado (diferencia entre stock actual y la cantidad proyectada de insumos) es menor o igual a este valor no se podría garantizar solventar la demanda.

Series temporales

Serie ordenada de eventos que se presentan a lo largo de un periodo [19]. Estas pueden tener diferentes comportamientos dependiendo de sus componentes (tendencia, estacionalidad y ciclos) [20]. En la investigación se realizó un análisis de serie temporal, ya que se disponía de datos de ventas pasadas. Esto permitió determinar su patrón de ventas para realizar las predicciones.

Pronósticos de ventas

Cantidad de ventas probables de un producto en un periodo definido [21]. En la investigación se empleó el pronóstico de demandada futura de un producto para calcular las cantidades de insumos necesarias a comprar.

Machine Learning

Conjunto de métodos que permiten identificar automáticamente patrones en los datos y predecir valores futuros [22]. La investigación utilizó el aprendizaje automático (ML) para desarrollar un modelo de predicción de ventas futuras.

Modelos de predicción

Son aquellos que emplean un mecanismo para predecir la manera de comportarse de un individuo, utilizando las características del individuo como entrada para obtener una salida en forma de calificación predictiva [23]. En el proyecto se emplearon tres modelos, que se explicarán a continuación.

ARIMA

Llamado promedio móvil integrado autorregresivo, es de tipo serie temporal. Es usado en el pronóstico de una variable a futuro en función a su relación con las demás variables [24].

Prophet

Desarrollado por Facebook y utilizado en el pronóstico de series temporales comerciales [25]. Se caracteriza por incluir componentes de tendencia, estacionalidad y efectos de vacaciones [25]. En la investigación, se determinó que las ventas son afectadas por los días festivos, por lo que en la implementación de este modelo se incorporó su influencia para obtener un resultado más preciso.

RNN –LSTM

Es un tipo de red neuronal recurrente (RNN) utilizado para el procesamiento de texto, videos y datos de series temporales [26]. Está compuesto por RNN y una celda de memoria capaz de almacenar información a largo plazo [26]. En la investigación, se implementó este modelo utilizando tres capas: dos de ellas contenían celdas LSTM y una era una capa densa.

Random Forest

Es una técnica de aprendizaje supervisado empleado en tareas de predicción y clasificación [27]. Se caracteriza por utilizar múltiples árboles de decisión para construir un modelo más robusto [27]. En la investigación se consideró limitar la profundidad de los árboles para evitar un sobreajuste de la predicción, estableciendo una profundidad máxima de 200.

Métricas de evaluación de pronóstico

MAPE (Mean Absolute Percentage Error)

Medida del error del pronóstico expresada en porcentajes. Es calculada mediante el promedio de los errores porcentuales [28]. Por su fácil interpretación es útil para comparar modelos [28]. En la investigación esta métrica permitió seleccionar el modelo de predicción más ajustado a los datos de ventas, seleccionando aquel con el valor más bajo.

MSE (Median Square Error)

Evalúa que tan cercano fueron las predicciones de los valores reales [28]. Se calcula tomando en cuenta el promedio de error entre el modelo predictivo y los valores reales al cuadrado, y se usa para comparar diferentes modelos [28]. Esta métrica junto con MAPE fueron usadas para la selección del modelo predictivo.

FA (Forecast Accuracy)

Medida más común para determinar la precisión de un modelo, ya que es eficaz en la comparación entre proyecciones y datos concretos, donde los valores cercanos a uno determinan mayor precisión [29]. La investigación empleó esta métrica para calcular la precisión de los 30 modelos de predicción implementados.

Aplicación web

Son aplicaciones de software accedidas desde la web mediante el navegador [30]. En esta investigación se desarrolló una aplicación web para que el usuario pueda acceder rápidamente desde donde se encuentre.

Materiales y métodos

La investigación desarrollada fue de tipo aplicada, tomando como referencia el manual de Frascati, ya que se busca determinar nuevas formas de alcanzar los objetivos específicos [31]. Asimismo, los resultados en este tipo de investigaciones se caracterizan por evidenciar su validez y aplicabilidad en productos, operaciones, métodos o sistemas [31].

Los métodos de investigación se describen en la siguiente tabla:

TABLA I
MÉTODOS DE INVESTIGACIÓN

Nombre	Descripción
Analítico	Este método se utilizó para el estudio y análisis de los problemas del restaurante.
Deductivo	Método empleado para proponer la predicción de ventas como propuesta de solución al problema.
Cuantitativo	Se empleó para al evaluar la cantidad de criterios que cumplen los modelos de predicción comparados

Se utilizó la entrevista para recabar datos sobre la problemática y los procesos de determinación de la demanda, empleado la guía de entrevista como instrumento. También se utilizó el análisis de documentos para el estudio y selección de los algoritmos de ML empleando como instrumento la ficha bibliográfica, este mismo fue empleado para revisar los datos de ventas usando la base de datos.

En la investigación se definió como variable independiente a la aplicación de predicción, ya que buscamos establecer la relación de esta con la planificación de compra de insumos. Asimismo, la variable dependiente o también llamada “de resultado” por [32], es justamente la planificación de compra de insumos, pues es el resultado de la ejecución de la variable independiente.

La población del estudio fue el historial de ventas del restaurante El nuevo Ferrocarril, que comprende 110 922 registros de ventas desde 2017 al 2021. La población también incluyó al administrador del restaurante, ya que se realizó una entrevista para obtener información sobre el negocio y los requerimientos de la aplicación.

Respecto a la muestra se empleó toda la población, debido a la exclusión del análisis de los registros de ventas para los años 2020 y 2021 (por ser años atípicos producto de la pandemia) manteniendo así la muestra en 110,922 registros de ventas para el análisis.

Resultados y discusión

Resultados

A continuación, se mencionan los resultados obtenidos siguiendo la metodología SCRUM.

Sprint 1

Durante este sprint, se recopiló información, planificación de historias de usuario y el desarrollo de algunas de ellas. A continuación, se muestra el desarrollo de cada fase.

Fase iniciar

Esta fase se centró en la obtención de información y definición de las bases de la investigación. Es importante aclarar que esta fase solo se realizó en este sprint, ya que no fue necesario volver a realizar ningún recojo de información adicional en los siguientes dos sprints.

Análisis de información de la empresa

Recopilamos información sobre el rubro de restauración y los procesos de la empresa a través de entrevistas. A continuación, se describen los hallazgos más importantes rescatados:

La ubicación del negocio cerca a la playa provoca variaciones en la demanda a lo largo del año, con picos durante la temporada de verano y los días festivos. Por esta razón, los procesos de abastecimiento deben ser lo más precisos posibles para evitar gastos excesivos durante los meses de baja demanda y garantizar la disponibilidad de insumos en los meses de alta demanda.

Mediante dos entrevistas, se determinó que el proceso de planificación de compras se basa en experiencias de compras pasadas, lo que provoca excesos o insuficiencias en la cantidad de insumos, además se determinó la precisión de los pronósticos empíricos realizados por el restaurante, para el mes de enero de 2019, obteniendo un valor de precisión de 0.49. Esta situación ocasiona que, en algunos casos, aproximadamente el 60% del exceso de insumos se utiliza, mientras que el 40% restante se desecha o se regala debido a su fecha de caducidad o falta de frescura. Por otro lado, la insuficiencia de insumos genera compras espontáneas en bodegas o mercados cercanos, con el consecuente sobre costo.

Se recomienda ver la guía de entrevista en los Anexos I, II y III.

El análisis de documentos permitió conocer el proceso de preparación del producto, para ello se empleó los diagramas de flujos de cada plato, determinando las relaciones de cada insumo.

Análisis de la información histórica de la base de datos




Fig. 1 Importe de ventas mensual por cada año

La figura 1, nos muestra la distribución del importe de ventas por mes en cada año, donde los meses están ordenados y se representan en números. De la figura anterior se pudo determinar que las ventas aumentan en enero, febrero, marzo y diciembre generando un importe mayor a los 5 000 nuevos soles en ventas, esto debido que el restaurante se ubica en una playa y durante estos meses la temporada de verano (vacaciones para la mayoría de los trabajadores) y los días festivos contiguos atraen público provocando un contexto de alta demanda e importes de ventas altos. Por otra parte, en el dataset de ventas de la empresa se encontraron 19 atributos, la cantidad de registros fue de 107 810, con tipos de datos float64(3), int64(6) y object(11).

Análisis de datos externos

El modelo de predicción consideró la influencia de los días festivos como factor externo que afecta a las ventas, por ello se empleó validación cruzada entre tres fuentes: “Diario Gestión”, “Calendario online” y la página de “Feriados nacionales”, esta última, empleada para verificar la precisión de la información, de esta forma se eligió a “diario gestión” como fuente primaria. Asimismo, los atributos considerados para el dataset de días festivos fueron dos: fecha y festividad; donde la fecha toma formato día-mes-año y de tipo date, mientras que festividad es una cadena que almacena el nombre de la festividad.

Definición de los roles

Siguiendo con las actividades de la metodología en esta primera fase se definieron tres roles dentro del proyecto, dos del tipo principal: Scrum Master y equipo Scrum (o de

desarrollo), así como un rol no esencial: stakeholder, esto con la finalidad de establecer las responsabilidades de cada miembro del equipo.

El rol de Scrum Master se definió para asegurar que se lleven a cabo los principios y procesos, del proyecto. Por otro lado, el equipo Scrum fue necesario para el creación y desarrollo de los entregables del proyecto, finalmente, el stakeholder, fue necesario para proporcionar información del negocio y establecer las características del producto [33].

Desarrollo de los epics

Se realizó elicitación de requisitos funcionales y no funcionales, a través de entrevistas con el administrador, definiendo los epics.

Definición de las epics e historias de usuario

Los siguiente epics se consideraron en el desarrollo de la investigación:

- Login: permite el acceso al sistema mediante un usuario y contraseña establecido.
- Usuarios: permite gestionar a los usuarios que utilicen el sistema para acceder a un módulo específico
- Ventas: permite gestionar productos, clase, subclases de productos y la receta, además de generar reportes de ventas.
- Compras: este permite llevar a cabo la gestión de compra de insumos, proveedores, almacén y generar reportes.
- Modelo de machine learning: construcción del modelo de ML para la predicción de compra de insumos.

Crear lista de pendientes del producto

La lista de pendientes del producto se realizó en función a los requerimientos, esta nos sirvió como guía para el desarrollo de las tareas prioritarias en cada sprint.

TABLA II
LISTA DE PENDIENTES DEL PRODUCTO

Ítem	Historia de usuario				Sprint Completado
	Código	Nombre de la historia de usuario	Prioridad	Esfuerzo estimado	
Nº1	HU1	Ingresar al sistema	4	2 puntos	Sprint 1
Nº2	HU2	Gestionar usuarios	6	5 puntos	Sprint 1
Nº3	HU3	Gestionar tipos de usuarios	6	3 puntos	Sprint 1
Nº4	HU4	Gestionar categoría de insumo	6	3 puntos	Sprint 1
Nº5	HU5	Gestionar insumo	6	5 puntos	Sprint 1

N°6	HU6	Gestionar clase	6	3 puntos	Sprint 1
N°7	HU7	Gestionar subclase	6	3 puntos	Sprint 1
N°8	HU8	Gestionar tipo de producto	6	3 puntos	Sprint 1
N°9	HU9	Gestionar receta	8	8 puntos	Sprint 1
N°10	HU10	Gestionar ventas	8	8 puntos	Sprint 2
N°11	HU11	Gestionar compras	8	8 puntos	Sprint 2
N°12	HU12	Gestionar proveedor	6	8 puntos	Sprint 2
N°13	HU13	Gestionar tipo de proveedor	6	3 puntos	Sprint 2
N°14	HU14	Gestionar almacén	6	5 puntos	Sprint 2
N°15	HU15	Reporte de predicción: Cantidad de insumos necesarios para una venta futura	8	7 puntos	Sprint 2

Fase planear y estimar

En esta fase se determinaron las actividades necesarias para el sprint.

Crear lista de pendientes del sprint

La lista de pendientes para este sprint abarcó la definición de las historias de usuario de la 1 a la 9 (mostrados en la Tabla II) , ya que son mantenimientos básicos necesarios para elaborar las operaciones transaccionales más complejas.

Fase Implementar

En esta fase se muestra el análisis bibliográfico sobre los modelos de predicción de ventas a evaluar, la limpieza y análisis de los datos de ventas, así como el desarrollo de las historias de usuario pendientes para el sprint.

Análisis bibliográfico sobre la implementación de modelos de machine learning

En esta sección se determinó el grupo de modelos de predicción que serán evaluados, para ello se realizó una revisión de literatura seleccionando investigaciones: con un problema igual o similar y el uso modelos de predicción de ventas basados en ML (Machine Learning – Aprendizaje automático) con resultados favorables a la solución. A continuación, se describen las investigaciones seleccionadas.

TABLA III
LISTA DE INVESTIGACIONES SELECCIONADAS

Referencia	Problema	Modelo	Características	Resultado
[34]	Previsión de ventas y manejo de las existencias	Media móvil autorregresivo integrada (ARIMA), Red neuronal recurrente de memoria a largo plazo (RNN-LSTM).	La investigación emplea un modelo de agrupamiento previo. Ambos métodos pueden emplearse en predicción con series temporales.	El modelo de mejor predicción fue evaluado en función al porcentaje de ahorro en costos, siendo ARIMA el de mejor porcentaje de ahorro frente al costo real con un 83%.
[35]	Ausencia de herramienta para la planificación de personal.	Random Forest, Modelo Prophet	Random Forest resuelve problemas tipo predicción y clasificación Modelo Prophet resuelve problemas de predicción	Medido a través de la precisión del modelo con MAPE (Mean absolute percentage error) Ambos modelos obtuvieron resultados favorables en la precisión, Random Forest (88.98%) y modelo Prophet (88.46%).
[36]	Pronóstico de ventas para manejar inventario de medicamentos	ARIMA	Empleo de correlación cruzada de ventas para encontrar grupos de medicamentos. Los modelos son empleados en problemas de series temporales. ARIMA es de tipo serie temporal lineal, mientras que RNA híbrido es de tipo no lineal.	La predicción con ambos modelos fue óptima, sin embargo, el modelo RNA híbrido propuesto fue mejoró a ARIMA. La formación de grupos de medicamentos con relación a su comportamiento con las ventas ayudó a mejorar los resultados de la predicción.

La tabla III nos muestran las investigaciones que permitieron seleccionar los modelos a evaluar: ARIMA, Random Forest, Prophet y RNN LSTM, para su análisis y posterior selección en la aplicación.

Diseño del dataset

En esta sección se definió el total de datos y las variables que conformarán el dataset.

Obtención de los datos

Se realizó una unión entre los datos de ventas y días festivos, además se limitaron los datos de análisis para los años 2017 al 2019, ya que los datos del año 2020 son atípicos por causa de la pandemia de COVID-19, lo cual afectarían la precisión del modelo. Obteniendo un total de 107 810 registros.

Identificación de variables dependientes e independientes

La variable dependiente fue el atributo “cantped”, ya que se buscaba predecir la cantidad de ventas. Además, se limitó el número de variables empleando correlación de variables numéricas. Para las variables categóricas se seleccionó el identificador del producto, el nombre del producto, el nombre de la festividad y la fecha de compra.

Verificación de la calidad de los datos

La evaluación de calidad de datos encontró problemas de duplicidad de datos ya que, algunos productos tenían códigos compartidos, esto debido a que durante los tres años de análisis los productos han variado de nombre o han sido registrados dos veces teniendo productos con nombre “P. FRITO CHITA (PRIN)” y “PESC. FRITO ' con el mismo identificador. Para ello se realizó la modificación dejando únicamente un solo nombre para cada identificador del producto.

Análisis exploratorio de la serie temporal

Se modificó la fecha, a un periodo semanal, ya que el modelo realizará predicciones semanales. A continuación, se muestra el análisis del patrón de ventas realizado en dos productos: Arroz con mariscos y Ceviche mixto.



Fig. 2 Número de ventas semanales de arroz con marisco



Fig. 3 Número de ventas semanales de ceviche mixto

Las figuras 2 y 3 muestran picos altos y bajos en diferentes periodos del año, este comportamiento está vinculado a las fechas festivas, por ejemplo, entre enero y marzo las ventas se incrementaron alcanzando hasta 80 transacciones semanales y durante esos meses se celebra año nuevo y Semana Santa.

Se descompuso la serie temporal identificando que la tendencia era no lineal, pues tiene picos altos y bajos. Asimismo, la estacionariedad se determinó con prueba de Dickey-Fuller [37], obteniendo un p valor de 0.01159 indicándonos que la serie tiene una media y varianza de ventas constante, asimismo, se empleó autocorrelación [38] para identificar estacionalidad, obteniendo un valor positivo de 0.65. Esto nos indica que la serie presenta unos periodos con patrones repetitivos, producto de la influencia de los días festivos.

Desarrollo de la aplicación web

A continuación, se muestran las interfaces desarrolladas más importantes

Fig. 4 Interfaz agregar receta

Fase revisión y retrospectiva

En esta fase se realizó la definición y ejecución del plan de pruebas para las historias de usuario definidas en la lista de pendientes del sprint.

Plan de pruebas

En esta sección se realizó la planificación de las pruebas de caja blanca.

Criterios de entrada y salida

Criterios de entrada

- Aplicación web – Perfil administrador
- Reporte de predicciones
- Criterios de salida
- Casos de prueba
- Defectos hallados

Estrategia de prueba

- Requerimientos funcionales

Requerimientos de hardware y software

- Instalación del gestor de base de datos PostgreSQL.
- Instalación del framework Flask y las librerías de desarrollo asociadas.
- Usuario y contraseña de un usuario de administrador.

Sprint 2

Durante este sprint, se realizó la elección, desarrollo y evaluación del modelo de predicción de ventas, así como parte del desarrollo de las historias de usuario.

Fase Planear y estimar

En esta fase se realizó la planeación de todos los entregables para este sprint.

Crear lista de pendientes del sprint

La lista de pendientes en este sprint abarcó las historias de usuario de la 10 a la 14, en los que se cubre los principales procesos del negocio.

Fase implementar

Se realizó la elección, desarrollo y evaluación del modelo de predicción de ventas, además se implementaron las historias de usuario de la lista de pendientes del sprint.

Desarrollo del modelo

En esta sección se describe el desarrollo del modelo de predicción de ventas, empezando por la elección del modelo que mejor se ajuste a los datos de ventas.

Elección del modelo de predicción

Las métricas de evaluación MAPE Y MSE permitió comparar los modelos de pronósticos candidatos, para ello se realizó la implementación de los modelos ARIMA, Random Forest, RNN LSTM y Prophet con datos de ventas reales de 2017 a 2019. Se realizó la división del dataframe en 80% para entrenamiento y 20% para pruebas. La comparación empleó los primeros 5 productos más vendidos: Tortita de choclo, Cev.Mixto, Cev. Toyo, Arroz con Mariscos y Maracuyá. A continuación, la Tabla VI muestra la comparación entre los modelos.

TABLA IV
COMPARACIÓN DE LOS MODELOS CANDIDATOS

Modelos	Cev. Mixto		Cev. Toyo		Arroz c/mariscos		Maracuyá 1L		Tortita de choclo	
	MSE	MAPE	MSE	MAPE	MSE	MAPE	MSE	MAPE	MSE	MAPE
ARIMA	209.56	27.46	190.46	44.84	102.03	25.67	120.01	47.68	2350.31	24.88
Random Forest	186.14	25.77	195.29	51.22	107.65	24.93	105.41	47.82	2460.97	22.84
RNN-LSTM	188.35	26.98	244.86	50.45	101.86	26.12	102.32	48.68	2380.23	22.62
Prophet	160.85	24.46	188.42	47.96	90.17	23.68	90.88	45.91	2156.49	20.72

La tabla IV nos muestra que Prophet obtuvo los mejores valores para los productos "Cev. Mixto", "Cev. Toyo", "Arroz c/mariscos", "Maracuyá 1L" y "Tortitas de choclo", con valores de MSE y MAPE de 160.85 y 24.46, 188.42 y 47.96, 90.17 y 23.68, 90.88 y 45.91, y 2156.49 y 20.72, respectivamente. Esto considerando que estas métricas cuantifican el error, por lo que los valores más bajos son los valores más efectivos [28]. Además, se calculó la media de estos valores para proporcionar una perspectiva global obteniendo un MSE de 537.36 y MAPE 14,16%.

Implementación de los modelos predicción

Finalmente, tras seleccionar el modelo de predicción se pasó a generar un modelo para cada producto del restaurante. El entrenamiento de cada modelo se realizó con 157 datos semanales, generando 30 modelos, empleando una configuración individual para cada modelo, por lo que se utilizó búsqueda de cuadrícula.

Evaluación de la precisión de los modelos

Esta sección detalla la validación de la precisión en los 30 modelos de pronóstico de ventas implementados. El propósito fue asegurar que los resultados de predicción se alinearan con las ventas reales, para ello se utilizó la métrica FA (Forecast Accuracy - Precisión del pronóstico) y los datos de ventas recopilados desde octubre de 2023 hasta la primera semana de septiembre de 2023. La fórmula para calcular el FA se especifica a continuación:

$$FA = 1 - \frac{\sum \|Demanda\ real - Forecast\|}{Demanda\ real} \quad [39]$$

Para su cálculo se desarrolló una función para calcular el FA de cada modelo y promedio de todos ellos. El código se muestra en la figura 5.

```
def forecastAccuracy(y_true: DataFrame, y_pred: DataFrame) -> float:
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    sum_abs_errors = np.sum(np.abs(y_true - y_pred))
    sum_true = np.sum(y_true)
    fa = (1 - (sum_abs_errors / sum_true))
    return fa

def calculateForecastAccuracy(test_list, forecast_list):
    fa_results = []

    for test_data, forecast_data in zip(test_list, forecast_list):
        fa = forecastAccuracy(test_data['y'], forecast_data['yhat'])
        fa_results.append(fa)

    total_fa = sum(fa_results) / len(fa_results)
    return fa_results, total_fa
```

Fig. 5 Función para evaluar el FA en todos los modelos

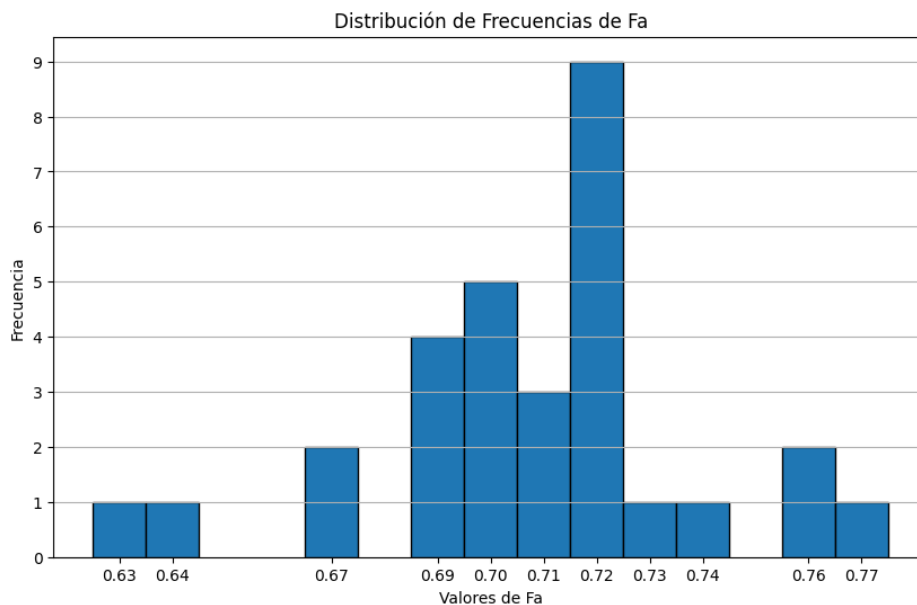


Fig. 6 Distribución de frecuencias de FA

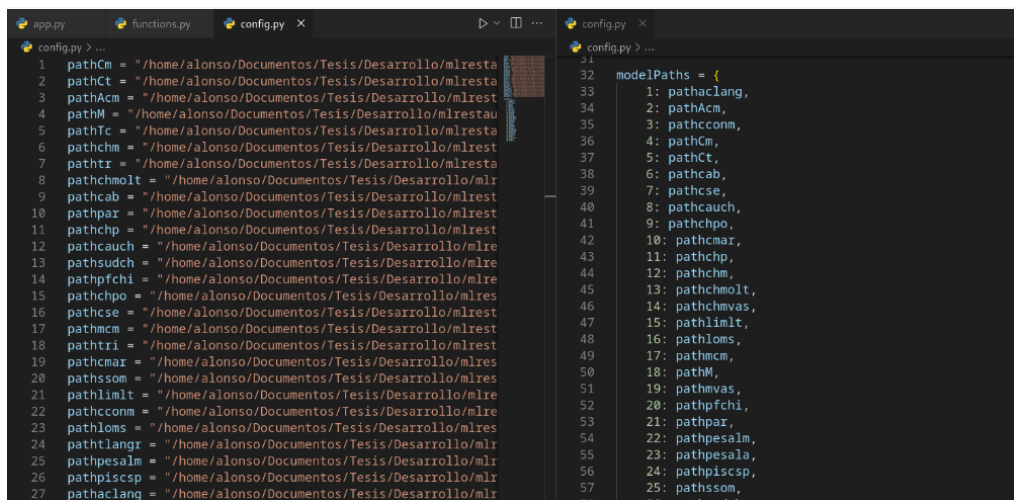
Con los resultados de FA obtenidos, se elaboró un gráfico de distribución de frecuencias presentado en la figura 6. La figura nos muestra que los valores obtenidos están entre 0.63 y 0.77, donde el 43% de los modelos obtuvieron valores menores o iguales a 0.7, mientras que el 57% obtuvo valores entre 0.71 a 0.77. Asimismo, se calculó el promedio de FA de todos los modelos para obtener un resultado general, obteniendo un valor de 0.71. Según [29] la forma de valorar un nivel de FA es mediante su cercanía a 1, por lo que mientras los valores sean más cercanos a 1 se obtendrá una mejor precisión; ahora bien, para determinar a que nivel de precisión debería aspirar el modelo consideramos el enfoque recomendado por [40] en el que se compara la precisión obtenida con los estándares internos del negocio, por lo que se comparó la precisión de los pronósticos de ventas iniciales de la empresa de 0.49 con el 0.71 obtenido, permitiéndonos afirmar que en términos de precisión el modelo obtuvo una alta valoración, ya que comparado con el nivel de precisión anterior hemos logrado una mejora de 0.22, pudiéndose integrar eficazmente en la aplicación web para una proyección de ventas fiables. Después de comprobar una alta precisión en cada modelo se pasó a exportar cada uno en formato “. pkl” usando la librería “pickle”.

Desarrollo de la aplicación web

En esta sección se realizó la implementación de una API que atienda las solicitudes de la aplicación web, además se desarrollaron las historias de usuario de la lista de pendientes del sprint.

Desarrollo de la API

Se implementó una API para cargar los modelos de predicción de cada producto, para ello se empleó la herramienta FastApi. En la API se definieron tres archivos, el primero llamado “app.py” contenía la configuración inicial para levantar el servidor y los componentes básicos de la API, “config.py” contenía las rutas para acceder a los modelos y “functions.py” contenía las funciones para cargar los modelos y obtener las predicciones.



```

1 pathCm = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
2 pathCt = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
3 pathAcM = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
4 pathM = "/home/alonso/Documentos/Tesis/Desarrollo/mlrestau
5 pathTc = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
6 pathChm = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
7 pathTr = "/home/alonso/Documentos/Tesis/Desarrollo/mlresta
8 pathChmolt = "/home/alonso/Documentos/Tesis/Desarrollo/mlr
9 pathCab = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
10 pathPar = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
11 pathChp = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
12 pathCauch = "/home/alonso/Documentos/Tesis/Desarrollo/mlre
13 pathSudch = "/home/alonso/Documentos/Tesis/Desarrollo/mlre
14 pathPfchi = "/home/alonso/Documentos/Tesis/Desarrollo/mlre
15 pathChpo = "/home/alonso/Documentos/Tesis/Desarrollo/mlres
16 pathCse = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
17 pathMcm = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
18 pathTri = "/home/alonso/Documentos/Tesis/Desarrollo/mlrest
19 pathMar = "/home/alonso/Documentos/Tesis/Desarrollo/mlres
20 pathSom = "/home/alonso/Documentos/Tesis/Desarrollo/mlres
21 pathLimit = "/home/alonso/Documentos/Tesis/Desarrollo/mlre
22 pathConm = "/home/alonso/Documentos/Tesis/Desarrollo/mlre
23 pathLoms = "/home/alonso/Documentos/Tesis/Desarrollo/mlres
24 pathLangr = "/home/alonso/Documentos/Tesis/Desarrollo/mlr
25 pathPsalM = "/home/alonso/Documentos/Tesis/Desarrollo/mlr
26 pathPiscsp = "/home/alonso/Documentos/Tesis/Desarrollo/mlr
27 pathLang = "/home/alonso/Documentos/Tesis/Desarrollo/mlr

31
32 modelPaths = {
33 1: pathClang,
34 2: pathAcM,
35 3: pathConm,
36 4: pathCm,
37 5: pathCt,
38 6: pathCab,
39 7: pathCse,
40 8: pathCauch,
41 9: pathChp,
42 10: pathMar,
43 11: pathChp,
44 12: pathChm,
45 13: pathChmolt,
46 14: pathChmvas,
47 15: pathLimit,
48 16: pathLoms,
49 17: pathMcm,
50 18: pathM,
51 19: pathMvas,
52 20: pathPfchi,
53 21: pathPar,
54 22: pathPsalM,
55 23: pathPsalA,
56 24: pathPiscsp,
57 25: pathSom,
58 26: pathSudch

```

Fig. 7 Modelos de predicción por producto

La figura 7 muestra el contenido del archivo “config.py”, en el que se encuentra la definición de las rutas para los 30 modelos de cada producto.

Por otra parte, también se realizó el desarrollo de las historias de usuario de la lista de pendientes.

Fase revisión y retrospectiva

En esta fase se realizó la ejecución del plan de pruebas para las historias de usuario definidas en la lista de pendientes del sprint.

Sprint 3

En este sprint se realizó la integración de la aplicación con la API, así como el desarrollo del reporte de predicción de cantidad de insumos a comprar. Asimismo, solo en este último sprint se desarrolló la fase

Fase planear y estimar

En esta sección se definieron las historias de usuario pendientes en la lista de pendientes.

Crear lista de pendientes del sprint

La lista de pendientes para este sprint se basó en la integración de la aplicación web con la API y las pruebas de calidad de la aplicación. Además de la historia de usuario 15 relacionada con el reporte de predicción de cantidad de insumos necesarios a comprar.

Fase Implementar

En esta sección se implementa lo definido en la lista de pendientes del sprint anterior.

Desarrollo de la aplicación web

El desarrollo inicia con la integración entre API y aplicación, para luego realizar el reporte de predicción.

Integración de la API con la aplicación web

La integración de la API a la aplicación web se realizó desde el módulo de compras, en el cual se desarrolló una función de acceso al reporte de predicción de cantidad de insumos necesarios a comprar.

```

API_URL = 'http://localhost:8000/prediction'

@compras_bp.route("/compras/dashboard", methods=["GET", "POST"])
@login_required
def dashboard():

    numberWeeks = None

    listaProductos = get_data_products()
    ltiposProveedor = [{'id':c.id, 'nombre':c.nombre} for c in Tipo_proveedor.query.all()]

    if request.method == "POST" and request.headers.get('X-Requested-With') == 'XMLHttpRequest':

        if request.json.get('btn') == 'btnConsultar':

            listProductsId_str = request.json.get('listaIdProductos')
            listProductsId = list(map(int, listProductsId_str))
            numberWeeks = request.json.get('numeroSemanas')

            data = PredictionData(listId=listProductsId, numberWeek=numberWeeks)

            try:

                response = requests.post(API_URL, json=data.model_dump())
                response.raise_for_status()
                result = response.json()

            except requests.RequestException as e :
                print('Error en la solicitud: ', e)

```

Fig. 8 Integración de la API

La figura 8 muestra el uso del “endpoint” de la API definido en la constante `API_URL`, el cual recibe el número de semanas ingresadas y la lista de productos a predecir, todo ello se maneja a través de una sentencia “try except” para manejar un posible error a través de un mensaje en consola.

Por otro lado, también se desarrolló la interfaz para el reporte de predicción de cantidad de insumos necesarios a comprar. A continuación, se muestra la interfaz desarrollada.

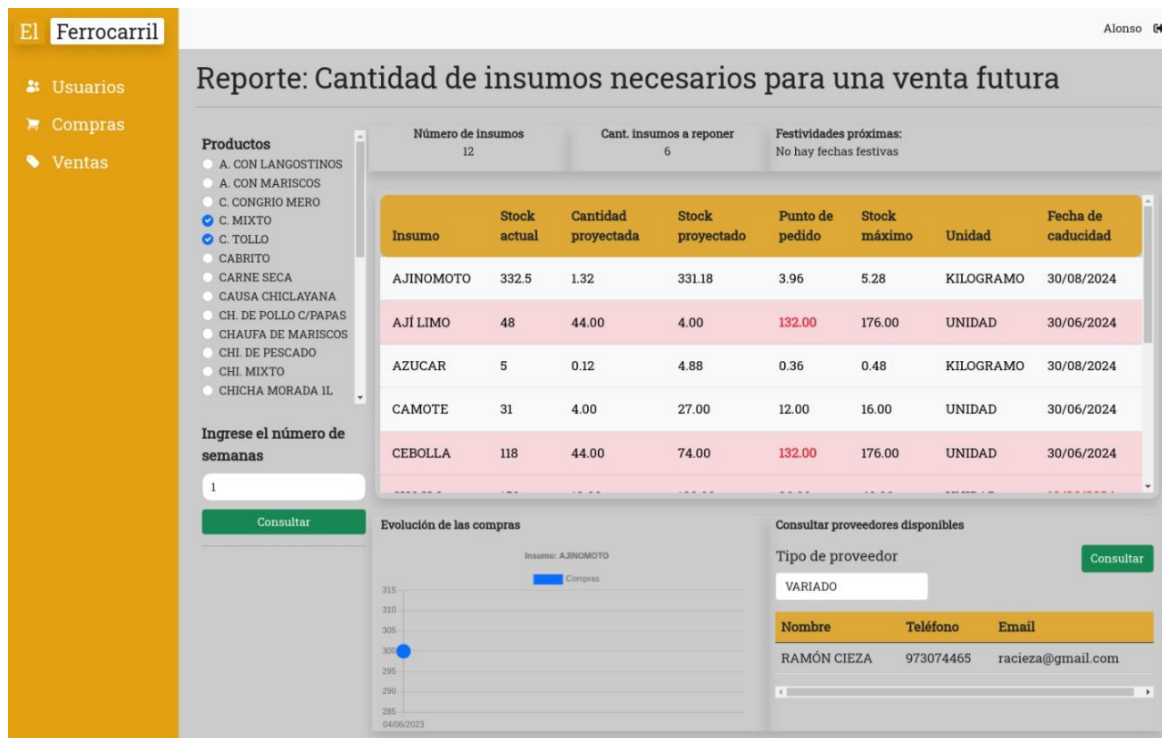


Fig. 9 Reporte de predicción de cantidad de insumos necesarios a comprar

La figura 9 muestra la interfaz del reporte de predicción de insumos necesarios a comprar, el cual permite al usuario interactuar con los modelos de predicción de ventas de cada producto, para determinar qué, cuánto y cuándo comprar. El reporte muestra alertas basadas en el punto de pedido y la fecha de caducidad. El punto de pedido determina si la cantidad de stock proyectado de un insumo es suficiente para solventar la demanda futura hasta la próxima compra. Si el stock proyectado es menor al punto de pedido, la fila del insumo se resalta en rojo. Por ejemplo, para la cebolla, el stock proyectado es de 74 unidades frente a un punto de pedido de 132 unidades, indicando necesidad de reposición, asimismo, se observa que a pesar que el stock proyectado para la cebolla es mayor a cero esta cantidad no garantiza solventar la demanda futura, ya que no considera el tiempo de retraso en una compra de insumos o el stock de seguridad de cada insumo. Además, la alerta también se activa sobre insumos con fechas vencidas.

El reporte calcula la cantidad mínima (mediante la resta entre punto de pedido y el stock proyectado) y máxima (usando el stock máximo) de insumos a comprar, muestra un gráfico de compras del año anterior para el mismo mes en que se generó el reporte, y proporciona una lista de proveedores disponibles. También incluye tres indicadores resumen: cantidad total de insumos por predicción, cantidad de insumos a reponer y coincidencia con fechas festivas, esta última ya que las ventas se ven influenciadas por los días festivos facilitando una mejor planificación de compras.

Evaluación de la calidad de la aplicación web

Se evaluó la calidad de la aplicación web mediante la característica "eficiencia de desempeño" o "rendimiento", en adelante rendimiento, definida en ISO/IEC 25010 [36]. Tomando lo mencionado por [37] en una evaluación de calidad de una aplicación web no se puede abarcar todas las características en una sola evaluación, por lo que es crucial centrarse en evaluar la característica más importante: el rendimiento, que mide la eficiencia de la interacción entre usuario y programa. A través de la característica rendimiento se podrá determinar que la aplicación no contenga componentes con rendimiento que llegue a alterar el sistema, garantizando así la calidad de una aplicación web [41]. Para ello, se utilizó Lighthouse, una herramienta automatizada que permite medir el rendimiento de la aplicación [42]. Las puntuaciones de rendimiento se calculan ponderando 5 métricas: First Contentful Paint, Speed Index, Largest Contentful Paint, Time Blocking Time y Cumulative Layout Shift [42].

Para evaluar el rendimiento, se auditó un total de 41 interfaces correspondientes a los 14 módulos de la aplicación. Cada interfaz se evaluó en cuatro ocasiones, considerando que este valor puede variar debido a cambios en el tráfico de internet, el rendimiento del equipo, las extensiones del navegador, entre otros factores [42]. Posteriormente, se determinó el valor promedio de las evaluaciones por interfaz, obteniendo así su valor de rendimiento final.

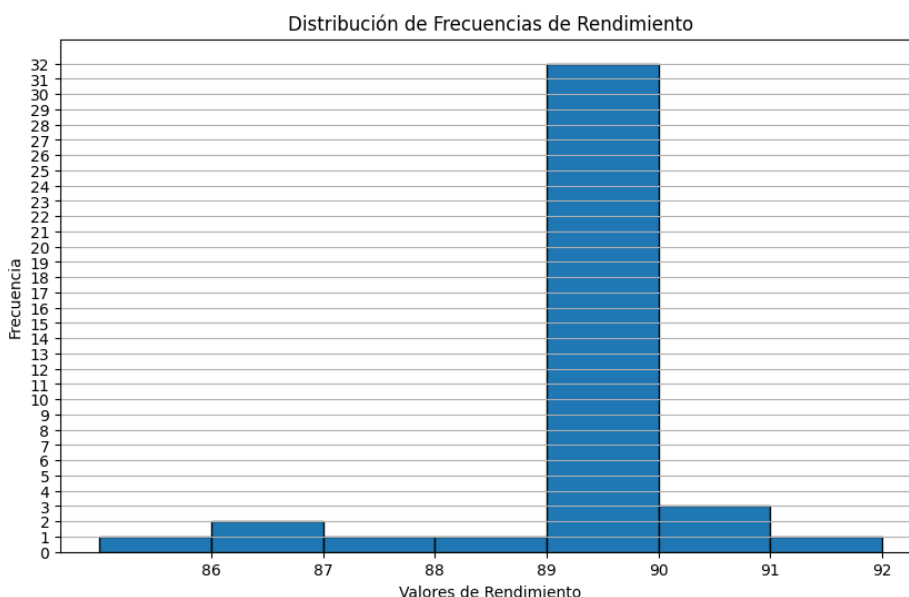


Fig. 10 Evaluación de rendimiento de la aplicación web

La figura 10 nos permite observar la distribución de frecuencias para los valores de rendimiento asociados a cada interfaz. El gráfico revela el 13% de las interfaces obtuvieron valores entre 81 a 89, mientras que el 87% lograron valores de 90 a 92. De acuerdo con los

criterios de Lighthouse, un puntaje de 0 a 49 es calificado como “deficiente”, de 50 a 89 como “necesita mejorar”, y de 90 a 100 como “bueno” [38]. Por lo tanto, se puede concluir que la mayoría de las interfaces (87%) alcanzan la clasificación de “bueno”, mientras que el 13% restante se encuentra en la clasificación de “necesita mejorar”. Asimismo, el promedio del rendimiento de las 41 interfaces es de 90, lo que sugiere que la aplicación tiene un rendimiento “bueno”, y garantiza que la calidad de la aplicación es buena (Revisar Anexo V).

Fase revisión y retrospectiva

En esta fase se llevaron a cabo pruebas sobre el producto terminado en tres aspectos: seguridad, portabilidad y rendimiento.

Prueba de seguridad

Objetivo: determinar que los nuevos usuarios cuenten con una contraseña encriptada, para evitar futuros ataques.

Acción: verificar la implementación de métodos de encriptación al guardar los datos del usuario.

Evidencia:

Uso del método `check_password_hash` en el modelo `User`, empleado para encriptar la contraseña del usuario.

```
class User(db.Model, UserMixin):
    __tablename__ = 'usuario'

    id = db.Column(db.Integer, primary_key=True, autoincrement=True)
    id_t_usuario = db.Column(db.Integer, db.ForeignKey("tipo_usuario.id"))
    nombre = db.Column(db.String(150), nullable=False)
    apellido = db.Column(db.String(200), nullable=False)
    usuario = db.Column(db.String(100), unique=True, nullable=False)
    clave = db.Column(db.String(200), nullable=False)
    email = db.Column(db.String(100), unique=True, nullable=True)
    telefono = db.Column(db.String(12), nullable=True)
    f_creacion = db.Column(db.DateTime, nullable=False, default=datetime.datetime.now)
    f_actualizacion = db.Column(db.DateTime, nullable=False, default=datetime.datetime.now)
    estado = db.Column(db.Boolean, nullable=False, default=False)
    ventas_usuario = db.relationship("Venta", foreign_keys=[Venta.id_usuario], back_populates = "usuarios")
    ventas_mozo = db.relationship("Venta", foreign_keys=[Venta.id_mozo], back_populates = "mozos")
    compras_usuario = db.relationship("Compras", foreign_keys=[Compras.id_usuario], back_populates = "usuarios")

    def __repr__(self):
        return f'<User {self.usuario}>'
    def set_password(self, clave):
        self.clave = generate_password_hash(clave)
    def check_password(self, clave):
        return check_password_hash(self.clave, clave)

    @hybrid_property
    def fullname(self):
        return self.nombre + " " + self.apellido
```

Fig. 11 Método de encriptación del usuario

Clave encriptada guardada en la base de datos

```

1 SELECT * FROM public.usuario
2 ORDER BY id ASC

```

id	id_usuario	nombre	apellido	usuario	clave	email	telefono
[PK] integer	integer	character varying (150)	character varying (200)	character varying (100)	character varying (200)	character varying (100)	character varying (10)
1	1	Alonso	Chiroque	alonso	pbkdf2_sha256_260000SPG3V8ZNRqZLlg5e504a4f17b6d1749ad1c20ad39d4e7612760bd214ff694abb2aa33bb...	alonsochiroque03@gmail.com	972974162

Fig. 12 Contraseña encryptada en la base de datos

Resultado: uso correcto de métodos de seguridad para los datos de inicio de sesión.

Prueba de portabilidad

Objetivo: determinar que la aplicación funciona bien en diferentes dispositivos.

Acción: iniciar la aplicación web desde un dispositivo móvil y web

Evidencia:

Se probó el inicio de la aplicación en un dispositivo móvil y web manteniendo un diseño adaptativo.

Proveedor	Usuario responsable	Fecha	Monto total	Estado
JORGE SANDOVAL	ALONSO	2023-11-04	750.00	INAC
RAMÓN CIEZA	ALONSO	2024-04-05	400.00	INAC
JORGE SANDOVAL	ALONSO	2023-11-06	10.00	ACTI
JORGE SANDOVAL	ALONSO	2023-11-05	10.00	ACTI
JORGE SANDOVAL	ALONSO	2023-11-05	25.00	ACTI

Fig. 13 Inicio de la aplicación en dispositivo móvil

Proveedor	Usuario responsable	Fecha	Monto total	Estado	Acciones
JORGE SANDOVAL	ALONSO	2023-11-04	750.00	INACTIVO	[Iconos de acción]
RAMÓN CIEZA	ALONSO	2024-04-09	400.00	INACTIVO	[Iconos de acción]
JORGE SANDOVAL	ALONSO	2023-11-06	10.00	ACTIVO	[Iconos de acción]
JORGE SANDOVAL	ALONSO	2023-11-05	10.00	ACTIVO	[Iconos de acción]
JORGE SANDOVAL	ALONSO	2023-11-05	25.00	ACTIVO	[Iconos de acción]

Fig. 14 Inicio de la aplicación en dispositivo web

Resultado: se observa una buena portabilidad de la aplicación.

Prueba de rendimiento

Objetivo: evaluar el rendimiento de la interfaz reporte de planificación de compra de insumos usando la predicción de ventas.

Acción: emplear lighthouse para medir el tiempo de ejecución del reporte de predicción.

Evidencia:

Obtención de 97 puntos de rendimiento para la interfaz “reporte de predicción: Cantidad de insumos necesarios para una venta futura”.

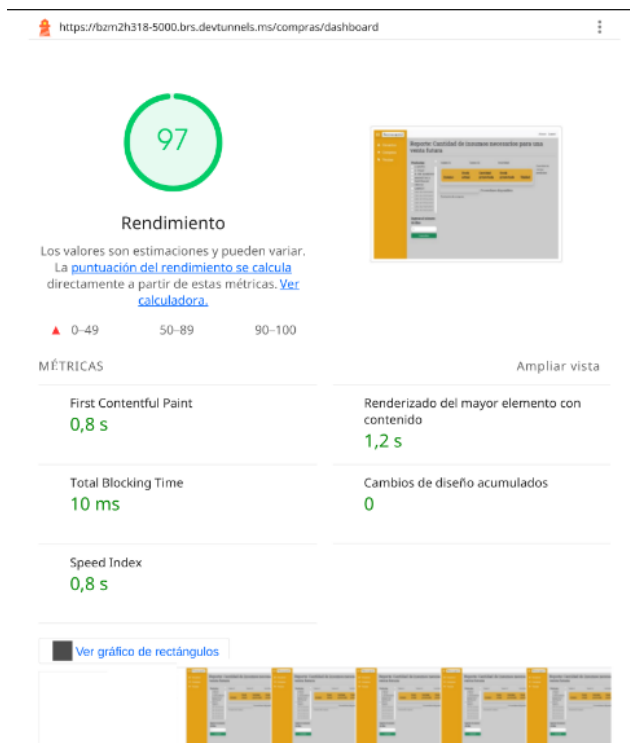


Fig. 15 Reporte de rendimiento

Resultado: métricas asociadas al rendimiento clasificadas como buenas. Rendimiento bueno de la interfaz para el reporte de insumos a comprar.

Discusión

La presente investigación desarrolló e implementó un modelo de predicción de ventas de productos en carta, con el objetivo de estimar con mayor precisión la cantidad de insumos necesarios para su preparación. En esta sección se discute los principales hallazgos, su relevancia práctica y su relación con estudios previos.

El cálculo de la cantidad de insumos a partir de las ventas fue empleado en las investigaciones de Feizabadi [8], Nassibi et al. [10], Camac [5], Farroñan [13], Santa Cruz [14] y Vilchez [15]. Ellos abordan las imprecisiones en la planificación de compras y gestión de stocks con la implementación de modelos de predicción de ventas que les permita una mejora en la estimación de la cantidad de insumos a comprar.

El modelo de predicción desarrollado integró análisis de series temporales y técnicas de ML (Machine Learning – Aprendizaje automático). A través del análisis de series temporales, se identificó que el comportamiento de las ventas era tanto estacionario como estacional, es decir, presentaba un patrón recurrente anual y variaciones dentro de cada año debido a un factor externo, los días festivos. Por su parte, el uso de ML permitió incorporar estos patrones identificados en un modelo predictivo, resultando en predicciones más precisas y eficientes. Esta forma de implementar un modelo de predicción también fue empleado en la investigación de Feizabadi [8], donde se desarrolló un modelo de predicción de demanda basado en ML y análisis de series temporales. Asimismo, autores como Nassibi et al. [10], solo emplearon ML, identificando la influencia de los factores externos ciudad y canal de distribución sin realizar un análisis previo de la serie temporal. Por otra parte, algunos autores emplearon un enfoque distinto como Nima et al [11], Custodio [12], Camac [5] que emplearon modelos estadísticos o Santa Cruz [14] y Vilchez [15] que emplearon minería de datos. Aunque, todas estas investigaciones lograron buenos resultados, esta investigación eligió combinar series temporales y ML debido a que la planificación de compras requiere de un resultado más preciso en el modelo de predicción [29].

La selección del modelo de predicción se realizó usando las métricas de precisión MAPE Y MSE para evaluar la precisión según el error, en los cinco primeros productos más vendidos. La elección de la métrica MSE difiere con la métrica RMSE usada por Nassibi et al. [10], para seleccionar su modelo de predicción, sin embargo, la presente investigación optó por MSE porque da mayor relevancia a los errores de mayor valor (por su naturaleza cuadrática) facilitando la comparación de los resultados [43].

Para evaluar la calidad de la aplicación, se utilizó Lighthouse para auditar 14 módulos en 4 evaluaciones. El valor de rendimiento para cada módulo se calculó como el promedio de estas

evaluaciones, evitando fluctuaciones y garantizando resultados precisos. Esta metodología coincide con la investigación de Vilchez [15], con la diferencia de que él solo realizó una evaluación por módulo en su aplicación.

En relación con el reporte de planificación de compras de insumos, se implementó un panel de control con información sobre la cantidad de insumos a adquirir según las predicciones de cada producto seleccionado.

Este panel emplea indicadores de reposición, como la fecha de caducidad y el punto de pedido, que alertan al usuario en caso de reposición. Esta forma de presentar la información es similar a la utilizada por SantaCruz [14] el cual implementó un dashboard de predicción de ventas para optimizar el proceso de compras usando Power BI. Contrario a esto se encuentran las investigaciones de Vilchez [15], el cual no utiliza un dashboard, sin embargo, empleó reportes gráficos calculando los productos a reponer en base al stock.

Conclusiones

En esta investigación se realizó el desarrollo de una aplicación web que facilita el cálculo de la cantidad de insumos a comprar mediante el uso de modelos de predicción de ventas. Con la finalidad de realizar una planificación de compras más eficiente. Para ello se alcanzaron los siguientes objetivos:

En la investigación realizamos la elección del modelo de predicción de ventas que mejor se ajuste a los datos, para ello se realizó una evaluación comparativa utilizando las métricas MSE y MAPE para los modelos ARIMA, Random Forest, RNN LSTM y Prophet. La evaluación empleó los datos de ventas para los cinco productos más vendidos: "Cev. Mixto", "Cev. Toyo", "Arroz c/mariscos", "Marcuyá 1L" y "Tortitas de choclo", destacando a Prophet como el modelo con mejores resultados por cada producto, con un promedio de MSE de 537.36 y MAPE de 14.16%. La elección del modelo sirvió para implementar los modelos de predicción para los 30 productos vendidos por el restaurante para luego poder comprobar su precisión.

Tras comparar la precisión de los pronósticos de ventas iniciales de la empresa con el promedio de la precisión de los 30 modelos de predicción de ventas por producto, calculada mediante la métrica FA, se observa una mejora significativa. Los modelos de predicción de cada producto lograron aumentar la precisión en 0.22 puntos respecto a los pronósticos iniciales. Este resultado indica que los modelos desarrollados, alcanzaron una valoración 'alta' en términos de precisión comparativa con los pronósticos iniciales de ventas. Si bien la precisión actual podría mejorar también se debe tomar en cuenta que la cantidad de datos de

entrenamiento que se vio reducida por la limpieza de datos, el agrupamiento de los datos en periodos semanales y el agrupamiento de los datos por cada producto.

La evaluación de calidad de la aplicación se realizó a través de la característica más importante de la norma ISO 25010: el rendimiento, para ello se empleó la herramienta Lighthouse auditando un total de 41 interfaces de los 14 módulos de la aplicación. Obteniendo que el 13% de las interfaces alcanzaron un rendimiento clasificado como “necesita mejorar”, mientras que el 87% alcanzó un rendimiento clasificado como “bueno”. Además, el rendimiento promedio de las 41 interfaces fue de 90, lo que clasifica el rendimiento general de la aplicación como “bueno”, permitiendo con este resultado poder garantizar una buena calidad de la aplicación.

Recomendaciones

Con la finalidad de complementar la investigación desarrollada se plantearon las siguientes recomendaciones:

La investigación empleó la influencia de los días festivos en el entrenamiento del modelo predictivo, debido a que este era un factor externo influyente en el comportamiento de las ventas, en futuras investigaciones se recomienda ampliar la inclusión de otros factores externos como el clima (precipitaciones o temperaturas) para obtener un modelo de predicción de ventas más preciso que tome cuenta varias variables.

En esta investigación se consideró utilizar la cantidad de ventas predichas para generar un reporte de planificación de compra de insumos, en este se calcularon indicadores como punto de pedido y stock máximo para que el usuario pueda determinar qué y cuantos insumos debería comprar. Para trabajos futuros se recomienda ampliar el resultado de la predicción de ventas con un modelo de gestión de inventarios de tipo determinístico, los cuales son usados cuando se conoce la cantidad de ventas futuras de un producto, para complementar la administración eficiente del inventario.

Referencias

- [1] Quintero Ortiz Brayan Camilo, “Costeo para un restaurante gourmet en Colombia,” Escuela de ingeniería de Antioquia, 2013.
- [2] F. Cuevas, *Control de Costos y Gastos en los restaurantes*, 1st ed. México: Limusa, S.A, 2002.
- [3] M. Canali *et al.*, “Food Waste Drivers in Europe, from Identification to Possible Interventions,” *Sustainability*, vol. 9, no. 1, p. 37, Dec. 2016, doi: 10.3390/su9010037.

- [4] J. Bharucha, “Tackling the challenges of reducing and managing food waste in Mumbai restaurants,” *Emerald Insight*, vol. 125, no. 1, pp. 639–650, 2017.
- [5] A. Camac, “IMPLEMENTACIÓN DE UN SISTEMA DE GESTIÓN DE COMPRAS PARA REDUCIR LOS COSTOS DE APROVISIONAMIENTO DE MATERIA PRIMA EN T.T. & J RESTAURANTE CEVICHERÍA EL SABOR SAC,” Universidad Privada del Norte, Lima, 2021.
- [6] C. M. Bernabe Chavez and L. R. Checa Torres, “Propuesta de mejora en la gestión de inventarios de micro y pequeñas empresas del sector gastronómico de la región Lambayeque para reducir sus mermas,” Universidad Tecnológica del Perú, Chiclayo, 2021.
- [7] E. Díaz Paniagua and M. León Sánchez, “Gestión administrativa y comercial en restauración,” 2014.
- [8] J. Feizabadi, “Machine learning demand forecasting and supply chain performance,” *International Journal of Logistics Research and Applications*, vol. 25, no. 2, pp. 119–142, Feb. 2022, doi: 10.1080/13675567.2020.1803246.
- [9] R. Chalán, “Análisis de los procesos de abastecimiento y distribución en planta de una cadena de restaurantes para el año 2023,” Universidad Tecnológica Empresarial de Guayaquil, Guayaquil, 2023.
- [10] N. Nassibi, H. Fasihuddin, and L. Hsairi, “Demand Forecasting Models for Food Industry by Utilizing Machine Learning Approaches,” (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, vol. 14, 2023.
- [11] E. Nima and A. Zavala, “Propuesta de mejora para reducir la rotura de stock en una empresa retail, aplicando Cycle Counting, pronósticos y estandarización,” Tesis de titulación, UNIVERSIDAD PERUANA DE CIENCIAS APLICADAS, Lima, 2024.
- [12] M. Custodio and V. Carranza, “Gestión de inventario para la mejora de la eficiencia operativa en un Minimarket en San Bartolo,” Tesis para optar título profesional, Universidad Ricardo Palma, Lima, 2023.
- [13] A. FARROÑAN, “SOLUCIÓN DE INTELIGENCIA DE NEGOCIOS PARA EL APOYO EN LA TOMA DE DECISIONES EN UNA EMPRESA PRIVADA,” Universidad Santo Toribio de Mogrovejo, Chiclayo, 2022.
- [14] L. Santa Cruz, “SISTEMA DE BI CON PREDICCIÓN DE VENTAS BASADOS EN EL ALGORITMO DE SERIES TEMPORALES PARA APOYAR LA GESTIÓN EN LA EMPRESA MOTOFUERZA S.A.C,” Universidad Santo Toribio de Mogrovejo, Chiclayo, 2021.

- [15] J. C. Vilchez Villegas, “Aplicación web de minería de datos para pronosticar la demanda de medicamentos en la farmacia de un establecimiento de salud,” Universidad Santo Toribio de Mogrovejo, Chiclayo, 2023.
- [16] K. Díaz Delgado, “Diseño de un sistema de gestión de compra para el restaurante "Mesón de la Plaza,” UCMAV, Santa Clara, 2016.
- [17] Gobierno de Chile, *Guías Prácticas Planificación de compra*.
- [18] A. Cruz, S. De prado, and P. Meseguer, *GESTIÓN LOGÍSTICA Y COMERCIAL*. Macmilan education.
- [19] M. Gonzáles, *Análisis de series temporales: Modelos ARIMA*. Sarriko On.
- [20] D. Salazar, “PRONÓSTICO DE VENTAS DE PRODUCTOS EN LA INDUSTRIA RETAIL EN BASE A SIMILITU DE SERIES DE TEMPORALES,” Título de ingeniero civil en computación, Universidad de Chile, Santiago, 2022.
- [21] J. Quispe Duran, “Impacto del modelo de minería de datos en el pronóstico de ventas de la empresa Cellservice EIRL. en el periodo 2012-2016,” UNC, Cajamarca, 2018.
- [22] D. Aguilar Florian and J. Alcocer Chaparro, “APLICACIÓN EN MACHINE LEARNING PARA OPTIMIZAR LA ATENCIÓN DE CLIENTES EN LA EMPRESA AUTOMOTRIZ A&S PALERMO SAC,” Univesidad San Martin De Porres, Lima, 2022.
- [23] X. Martinez and A. Daradoumis, ““Análisis predictivo: técnicas y modelos utilizados y aplicaciones del mismo - herramientas Open Source que permiten su uso,”” Trabajo de Fin de Grado, Universitat Oberta de Catalunya, 2017.
- [24] G. Vital, J. Quiterio, P. Miranda, and C. Soto, “Modelos ARIMA para el análisis sistematizado de criptomonedas,” *Padi*, vol. 11, pp. 1–7, 2023.
- [25] V. Papastefanopoulos, P. Linardatos, and S. Kotsiantis, “COVID-19: A Comparison of Time Series Methods to Forecast Percentage of Active Cases per Population,” *Applied Sciences*, 2020.
- [26] A. A. Ningrum *et al.*, “Deep learning hyperparameter optimization on power transformers lifetime prediction,” 2023, p. 060010. doi: 10.1063/5.0154959.
- [27] J. J. Espinosa Zúñiga, “Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito,” *Ingeniería Investigación y Tecnología*, vol. 21, no. 3, pp. 1–16, Jul. 2020, doi: 10.22201/fi.25940732e.2020.21.3.022.
- [28] J. Vélez and P. Nieto, “VALIDACIÓN DE MEDIDAS DE EVALUACIÓN PARA EL PRONÓSTICO DE LA TASA DE CAMBIO EN COLOMBIA,” Maestría, Colegio de Estudios Superiores de Administración –CESA–, Bogotá, 2016.

- [29] C. Sanchez, “MEDICIÓN EN LA PRECISIÓN DE LOS PRONÓSTICOS DE VENTAS Y SU EFECTO EN LOS COSTOS DE LA EMPRESA,” Universidad Andrés Bello, Concepción, 2017.
- [30] J. Almaraz, P. Campos, and T. Castelo, “Desarrollo de una aplicación Web para la gestión de Entornos Virtuales,” Universidad Complutense de Madrid, Madrid, 2011.
- [31] OECD, *Manual de Frascati 2015: GUIA PARA LA RECOPIACIÓN Y PRESENTACIÓN DE INFORMACIÓN SOBRE LA INVESTIGACIÓN Y EL DESARROLLO EXPERIMENTAL*. 2015.
- [32] M. Villasís and M. Miranda, “El protocolo de investigación IV: las variables de estudio,” *Rev Alerg Mex*, vol. 63, pp. 303–310, Jun. 2016.
- [33] SCRUMstudy, *Una guía para el conocimiento de scrum(guía sbok)*, Phoenix. 2013.
- [34] R. Puspita and L. A. Wulandhari, “Hardware sales forecasting using clustering and machine learning approach,” *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 11, no. 3, p. 1074, Sep. 2022, doi: 10.11591/ijai.v11.i3.pp1074-1084.
- [35] A. Gonzáles, “Herramienta de predicción de afluencia y optimización de la planificación de personal en el sector de restauración,” Madrid, 2019.
- [36] N. Khalil Zadeh, M. M. Sepehri, and H. Farvaresh, “Intelligent Sales Prediction for Pharmaceutical Distribution Companies: A Data Mining Based Approach,” *Math Probl Eng*, vol. 2014, pp. 1–15, 2014, doi: 10.1155/2014/420310.
- [37] R. Montero, “Variables no estacionarias y cointegración,” Granada, Mar. 2013.
- [38] Kirchner, “Serial correlation.”
- [39] E. Catalán, “Planificación de producción en modelo de optimización lineal con pronósticos de venta,” Universidad de Chile, Santiago, 2023.
- [40] G. Delorme, “WHAT IS A GOOD SALES FORECAST? About the forecast accuracy metric.”
- [41] S. Verona, Y. Pérez, L. Torres, M. Delgado, and Y. Cornelio, “Pruebas de rendimiento a componentes de software utilizando programación orientada a aspectos,” *Dialnet*, vol. 37, pp. 278–285, 2016.
- [42] Google developers, “Lighthouse.”
- [43] C. Á. Fierro Torres, V. H. Castillo Pérez, and C. I. Torres Saucedo, “Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características,” *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, vol. 12, no. 24, Jun. 2022, doi: 10.23913/ride.v12i24.1203.

Anexos

ANEXO I: Precisión de los pronósticos empíricos realizados en la empresa

TABLA V
VALORES DE FA POR CADA PRODUCTO

Producto	FA (Forecast Accuracy - Precisión del pronóstico)
A. Con mariscos	0.48
C. Mixto	0.64
C. Tollo	0.69
Maracuyá 1l	0.65
Tortitas de choclo	0.58
Chi. Mixto	0.56
T. De raya	0.49
Chicha morada 1l	0.51
Cabruto	0.71
Parihuela	0.51
Chi. De pescado	0.53
Causa chiclayana	0.45
Sudado de chita	0.44
P. Frito chita	0.45
Ch. De pollo c_papas	0.48
Carne seca c_y ch	0.44
Maracumango 1l	0.43
Triologia	0.40
Chaufa de mariscos	0.45
Sol Y sombra	0.42
Limonada 1l	0.48
C. Congrio mero	0.50
Lomito saltado	0.44
T. Lango-rayá	0.56
Pesc. A lo macho	0.45
Pisco sour promo	0.50
A. Con langostinos	0.35
Maracuyá vaso	0.38
Chicha morada vaso	0.50
Pesc. Al ajo	0.30

ANEXO II: Guía de entrevista 01**GUÍA DE ENTREVISTA**

Buenos tardes. Mi nombre es Nelson Alonso Chiroque Huamanchumo voy a realizarle una serie de preguntas para conocer la realidad del restaurante El Nuevo Ferrocarril.

Nombre del entrevistado: Bryan Amir Esparza Huamanchumo

Asume el cargo de: Administrador

Fecha: 20 de Septiembre de 2021

1. ¿Cuál es el rubro principal de su empresa?
2. ¿Cuál es la clasificación que recibe su empresa?
3. ¿Cuál es la visión de la empresa a largo plazo?
4. ¿Cuántos años lleva en funcionamiento?
5. ¿Qué clasificación tiene el restaurante?
6. ¿Cuáles son los roles definidos en la empresa?
7. ¿Qué tipo de productos ofrece la empresa?
8. ¿Qué tipo de clientes recibe regularmente?
9. ¿De qué otras formas ofrecen sus servicios a parte de la presencial?
10. ¿Cuenta con algún sistema electrónico para el desarrollo de sus actividades?
11. ¿Qué tipo de productos son los de mayor demanda?
12. ¿Durante qué periodos del año considera una mayor demanda por sus productos?
13. ¿Quiénes son sus principales competidores?
14. ¿Actualmente su empresa es más fuerte o débil que ellos?
15. ¿Qué diferencia tienen sus productos de los ofrecidos por su competencia?
16. ¿Actualmente venden más o menos que antes?
17. ¿De qué forma miden si han obtenido un mayor o menor número de clientes durante el mes o año?
18. ¿Utilizan esta información al realizar alguna decisión en la empresa?
19. ¿La carta es modificada en algún periodo del año?
20. ¿En qué se basa al momento de modificar la carta?
21. ¿Conocen el grado de satisfacción de sus clientes respecto al producto vendido?
22. ¿Qué acciones realiza la empresa para mejorar el grado de satisfacción con sus clientes?
23. ¿Qué datos registra en su sistema?
24. ¿Utilizan la información de sus ventas para tomar decisiones en la empresa?

ANEXO III: Guía de entrevista 02**GUÍA DE ENTREVISTA**

Buenos tardes. Mi nombre es Nelson Alonso Chiroque Huamanchumo voy a realizarle una serie de preguntas para conocer el estado del proceso de compras en el restaurante.

Nombre del entrevistado: Bryan Amir Esparza Huamanchumo

Asume el cargo de: Administrador

Fecha: 30 de septiembre de 2021

1. ¿Quién es el encargado de realizar las compras en el restaurante?
2. ¿Cómo describirías el proceso actual de planificación de compras en el restaurante?
3. ¿Qué criterios o factores influyen en la toma de decisiones de compras?
4. ¿Se realiza algún tipo de análisis previo antes de realizar las compras? Si es así, ¿cuál es?
5. ¿Cuál es la frecuencia con la que se realizan las compras de insumos o productos para el restaurante?
6. ¿Qué tan flexible es el proceso de planificación de compras para adaptarse a cambios en la demanda o en el menú?
7. ¿Cómo se determina la cantidad de productos a comprar en cada ocasión?
8. ¿Qué tipo de proveedores suelen utilizarse para las compras del restaurante?
9. ¿Existe algún sistema de inventario o control de existencias para gestionar las compras?
10. ¿Se tienen en cuenta consideraciones de temporada o tendencias del mercado al realizar las compras?
11. ¿Existieron ocasiones en los que la cantidad de insumos comprados fue mayor la cantidad de insumos requerida para suplir la demanda? Si es así ¿Qué cantidad lograron utilizar y qué cantidad se desperdicia?
12. ¿Existieron ocasiones en los que la cantidad de insumos comprados fue menor a la cantidad de insumos requerida para suplir la demanda? Si es así ¿Qué acciones suelen realizar en estos casos?
13. ¿Cómo se evalúa la calidad de los productos antes de realizar una compra?

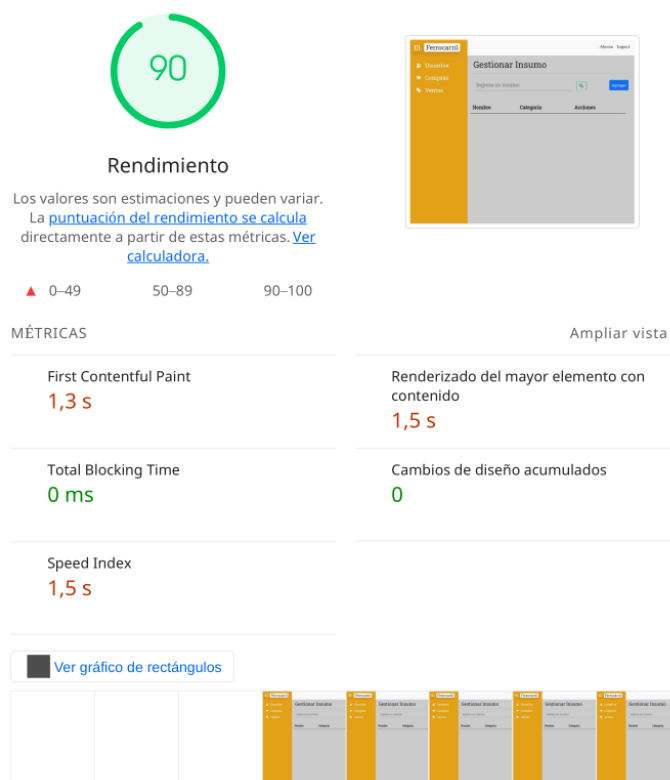
ANEXO IV: Porcentaje de ventas anuales del restaurante

TABLA VI
PORCENTAJE DE VENTAS

Año	Porcentaje de ventas
2017	100%
2018	97.57%
2019	92.83%
2020	66.39%
2021	75.32%
2022	78.23%
2023	70.21%

ANEXO V: Informe de rendimiento para los módulos principales

Módulo gestionar insumo – Página listar insumos



Módulo gestionar insumo – Página agregar insumo



Rendimiento

Los valores son estimaciones y pueden variar. La [puntuación del rendimiento se calcula](#) directamente a partir de estas métricas. [Ver calculadora.](#)

▲ 0-49 50-89 90-100



MÉTRICAS

Ampliar vista

First Contentful Paint 1,3 s	Renderizado del mayor elemento con contenido 1,5 s
Total Blocking Time 0 ms	Cambios de diseño acumulados 0,001
Speed Index 1,5 s	

[Ver gráfico de rectángulos](#)




Módulo gestionar insumo – Página modificar insumo



Rendimiento

Los valores son estimaciones y pueden variar. La [puntuación del rendimiento se calcula](#) directamente a partir de estas métricas. [Ver calculadora.](#)

▲ 0-49 50-89 90-100



MÉTRICAS

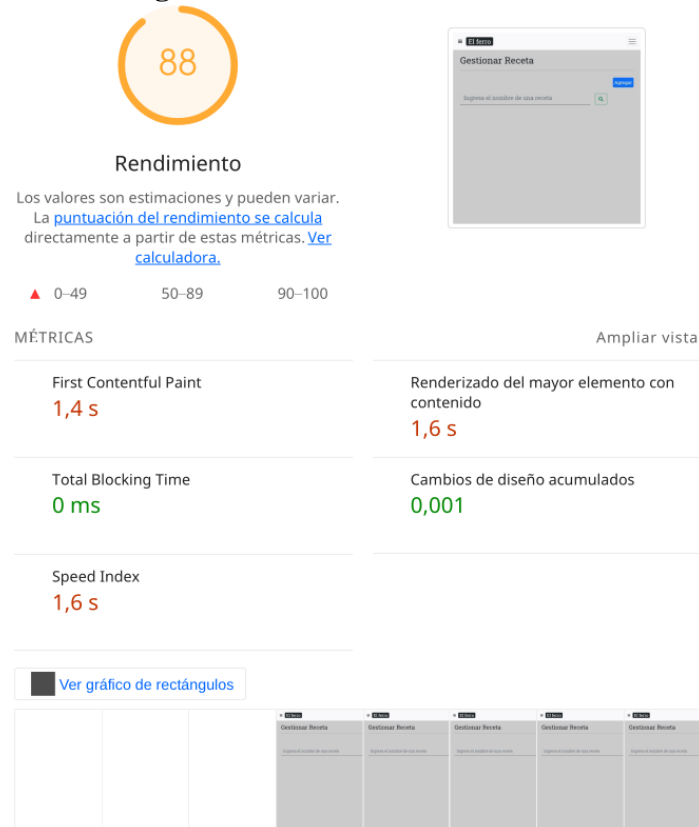
Ampliar vista

First Contentful Paint 1,3 s	Renderizado del mayor elemento con contenido 1,7 s
Total Blocking Time 0 ms	Cambios de diseño acumulados 0,001
Speed Index 1,5 s	

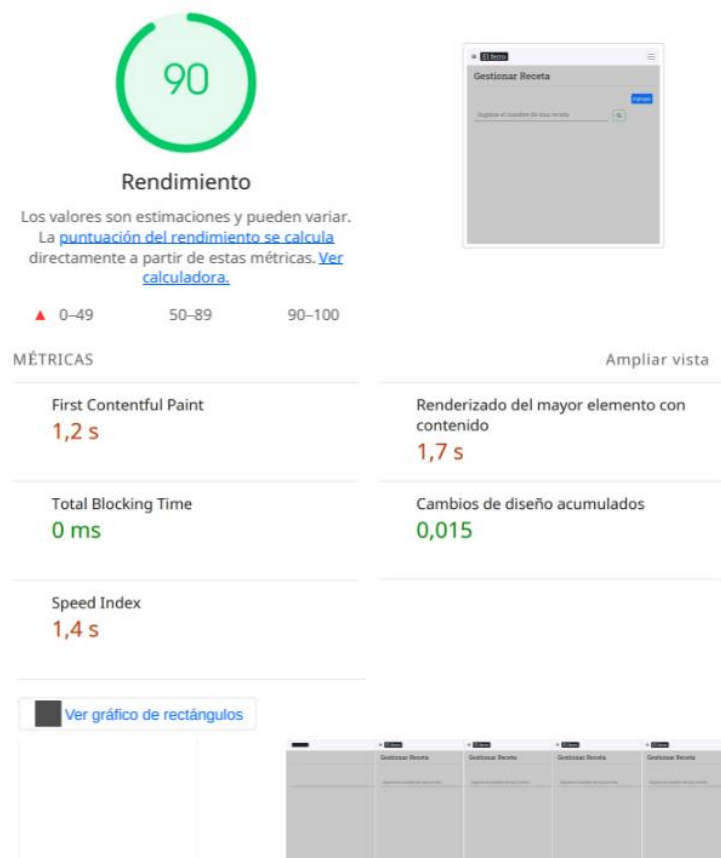
[Ver gráfico de rectángulos](#)



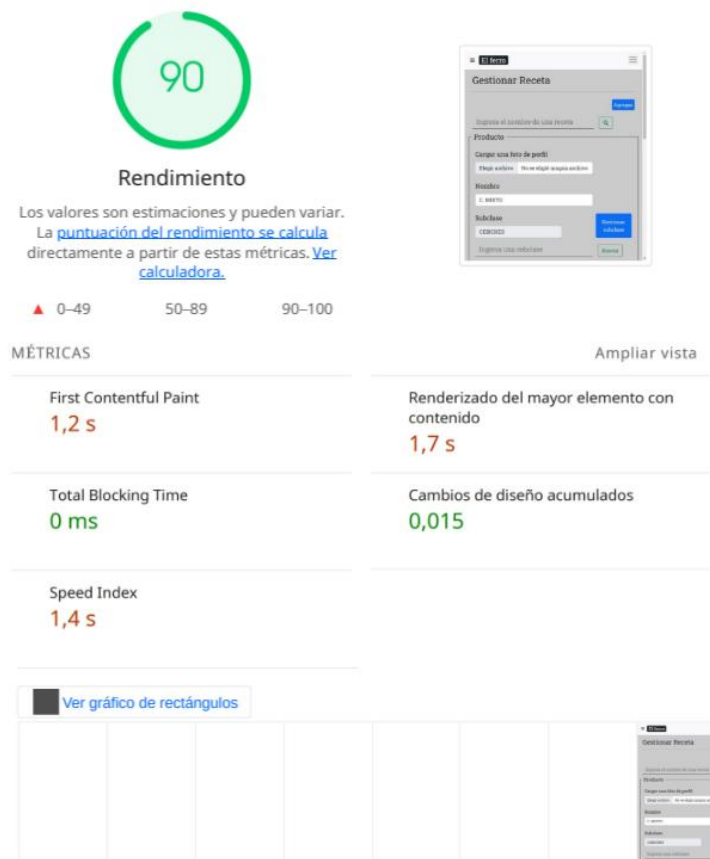
Módulo gestionar receta – Página listar receta



Módulo gestionar receta – Página agregar receta



Módulo gestionar receta – Página modificar receta



Reporte de predicción: Cantidad de insumos necesarios para una venta futura

