



Revista Micaela

ISSN: 2955-8646 (en línea) / 2709-8990 (Impresa)
Universidad Nacional Micaela Bastidas de Apurímac
Vice Rectorado de Investigación – Perú

Vol. 6 Num. 2 (2025) - Publicado: 18/12/25
<https://doi.org/10.57166/micaela.v6.n2.2025>
Páginas: 50 - 59

Recibido 13/11/2025 ; Aceptado 16/12/2025

<https://doi.org/10.57166/micaela.v6.n2.2025.187>

Edición Especial: Cosmovisión Andina – 2025

Autores:

1. ORCID iD <https://orcid.org/0009-0004-9354-5137> Royer Elvis Moreano-Condorcuya, estudiante de la Escuela Académica Profesional Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac, 1201remec@gmail.com
2. ORCID iD <https://orcid.org/0009-0003-6579-1042> Manuel Ángel Ríos-Peña, estudiante de la Escuela Académica Profesional Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac, 212135@unamba.edu.pe
3. ORCID iD <https://orcid.org/0009-0003-8054-9473> Lizbeth Ríos-Peña, estudiante de la Escuela Académica Profesional Ciencia Política y Gobernabilidad de la Universidad Nacional Micaela Bastidas de Apurímac, 221351@unamba.edu.pe
4. ORCID iD <https://orcid.org/0000-0002-3058-9683> Erech Ordoñez-Ramos, docente del Departamento de Ingeniería Informática y Sistemas de la Universidad Micaela Bastidas de Apurímac, eordonhez@unamba.edu.pe
5. ORCID iD <https://orcid.org/0000-0002-0258-8632> Alejandrina Huaylla-Quispe, docente del Departamento de Ingeniería Informática y Sistemas de la Universidad Micaela Bastidas de Apurímac, ahuaylla@unamba.edu.pe

which enabled the generation of dynamic predictions by product and department. Taken together, the findings demonstrated the effectiveness of machine learning for regional economic analysis and the formulation of evidence-based export policies.

Keywords: Exports, Machine learning, CatBoost, Prophet, Economic forecasting

1. Introducción

El comercio exterior constituye uno de los pilares del crecimiento económico del Perú, y su análisis a nivel departamental permite identificar brechas productivas y oportunidades de desarrollo regional. Sin embargo, la alta variabilidad

Predicción de exportaciones por departamentos en el Perú mediante modelos de Machine Learning y series temporales

Prediction of exports by department in Peru using Machine Learning models and time series

Royer Elvis Moreano Condorcuya¹, Manuel Ángel Ríos-Peña²,
Lizbeth Ríos-Peña³, Erech Ordoñez-Ramos⁴ y Alejandrina
Huaylla-Quispe⁵

Resumen. Este estudio presentó una aplicación de modelos de machine learning para la predicción de exportaciones por departamentos en el Perú, utilizando datos anuales del Banco Central de Reserva del Perú (BCRP) entre 2005 y 2022. Se evaluaron los algoritmos CatBoost, XGBoost, Linear Regression y Prophet, comparando su desempeño mediante las métricas MAE, RMSE, MAPE y R². Los resultados evidenciaron que el modelo CatBoost obtuvo un rendimiento superior, con un R² del 96.28 % y un MAE de 32.91 en validación. Le siguió Prophet, que alcanzó un MAPE del 3.75% y un RMSE de 72.15, mostrando alta precisión en series temporales. En contraste, Linear Regression presentó un R² de 82.72 %, lo que reflejó limitaciones para modelar relaciones no lineales. El modelo XGBoost, aunque competitivo, mostró un R² del 91.74 % con un RMSE de 163.58. Asimismo, se desarrolló un prototipo web funcional con Django y React para la visualización de resultados, el cual permitió generar predicciones dinámicas por producto y departamento. En conjunto, los hallazgos demostraron la eficacia del machine learning para el análisis económico regional y la formulación de políticas de exportación basadas en evidencia.

Palabras Clave: Exportaciones, Machine learning, CatBoost, Prophet, Predicción económica.

Abstract. This study presented an application of machine learning models for predicting exports by department in Peru, using annual data from the Central Reserve Bank of Peru (BCRP) between 2005 and 2022. The CatBoost, XGBoost, Linear Regression, and Prophet algorithms were evaluated, comparing their performance using the MAE, RMSE, MAPE, and R² metrics. The results showed that the CatBoost model performed superiorly, with an R² of 96.28% and an MAE of 32.91 in validation. Prophet followed, achieving a MAPE of 3.75% and an RMSE of 72.15, demonstrating high accuracy in time series. In contrast, Linear Regression presented an R² of 82.72%, reflecting limitations in modeling non-linear relationships. The XGBoost model, while competitive, showed an R² of 91.74% with an RMSE of 163.58. Additionally, a functional web prototype was developed using Django and React for visualizing results, which enabled the generation of dynamic predictions by product and department. Taken together, the findings demonstrated the effectiveness of machine learning for regional economic analysis and the formulation of evidence-based export policies.



de los mercados internacionales y la dependencia de sectores primarios dificultan realizar pronósticos precisos de exportaciones. En este contexto, los avances en machine learning y análisis predictivo ofrecen nuevas herramientas para modelar patrones complejos y mejorar la planificación económica.

Diversos estudios internacionales han demostrado la efectividad de estos métodos en la estimación de indicadores de comercio y desempeño logístico. Como demuestra los siguientes estudios realizado en, Croacia, República Checa, Indonesia [1][2][3]. Dichos trabajos coinciden en que los algoritmos de aprendizaje automático superan a los modelos cuantitativos tradicionales al capturar dinámicas multivariadas y comportamientos no lineales en los flujos de exportación. Siguiendo esta línea, el presente estudio propone la aplicación comparativa de cuatro algoritmos CatBoost, XGBoost, Linear Regression y Prophet para predecir las exportaciones departamentales del Perú. El objetivo principal es identificar el modelo más preciso y robusto, que pueda integrarse en un sistema de apoyo a la toma de decisiones para la gestión y promoción de las exportaciones regionales.

2. Antecedentes

En el trabajo de Gulzar et al. [4], se llevó a cabo la estimación de las exportaciones de alta tecnología de Turquía, con el propósito de apoyar su estrategia de crecimiento económico sostenible y orientado a la exportación. Los autores emplearon tres técnicas de machine learning: redes neuronales artificiales (ANN), regresión logística y máquinas de vectores de soporte (SVR), utilizando como variables independientes el producto nacional bruto, el número de patentes y el gasto en investigación y desarrollo, mientras que las exportaciones de alta tecnología fueron la variable dependiente. Los resultados demostraron que el modelo basado en ANN alcanzó el mejor desempeño con un coeficiente de determinación $R^2 = 94.2\%$, $MAPE = 0.011$ y $MSE = 0.073$, seguido por los modelos SVR y regresión logística. Este estudio evidencia la efectividad de las técnicas de aprendizaje automático para modelar relaciones complejas entre la innovación tecnológica y el crecimiento económico sostenible, sirviendo como referencia relevante para investigaciones que integran machine learning y análisis económico.

En el estudio realizado por Bassem Sellami, Chahinez Ounoughi, Tarmo Kalvet, Marek Tiits y Diego Rincón-Yanez (2024)[5], se aplicaron Graph Neural Networks (GNN) para predecir los flujos comerciales internacionales utilizando datos del UN Comtrade, que incluyen más de 5,000 productos y múltiples variables económicas como PIB, población, distancia y año. Los autores compararon los modelos Random Forest (RF), Graph Convolutional Network (GCN) y Graph Attention Network (GAT) mediante métricas de desempeño como R^2 , MAE, MSE y MAPE. Los resultados mostraron que el modelo GAT superó ampliamente a los métodos tradicionales, alcanzando un R^2 de hasta 0.95, con un MSE de 153.09 y un MAE promedio de 3.2, demostrando una gran capacidad para capturar las relaciones complejas entre países y productos. En comparación, el modelo Random Forest obtuvo un R^2 máximo de 0.64. El estudio concluye que las GNN ofrecen una herramienta eficaz para modelar las interdependencias del comercio global y mejorar la precisión en la predicción de exportaciones.

El estudio de Shashi Kumar R., Basavaraj M. S. y Vengalarao Pachava [6](2024) analizó la predicción de exportaciones de micro, pequeñas y medianas empresas (MIPYMES) mediante la comparación de modelos tradicionales de series temporales y técnicas avanzadas de machine learning. Se evaluaron modelos como Double Exponential Smoothing y ARIMA, junto con Support Vector Regression (SVR), Random Forest (RF) y Extreme Gradient Boosting (XGBoost), utilizando métricas de desempeño como RMSE, MSE, MAE, MAPE y R^2 . Los resultados mostraron que los métodos de machine learning superan ampliamente a los modelos tradicionales. El Random Forest alcanzó un R^2 de 0.9973 con un MAPE de 3.17%, mientras que el XGBoost obtuvo el mejor desempeño con un R^2 de 0.9983 y un RMSE de solo 0.02, aunque con indicios de sobreajuste. En contraste, el modelo ARIMA logró un R^2 de 0.9881 y un MAPE de 14.10%. Los autores concluyen que la combinación de enfoques tradicionales y de machine learning mejora la precisión en la predicción de exportaciones y apoya la formulación de estrategias de crecimiento para las MIPYMES.

3. Metodología

3.1 Diseño de investigación

El estudio se enmarca en un diseño no experimental con enfoque longitudinal retrospectivo, basado en la observación de datos anuales de exportaciones departamentales del periodo 2005–2022. Este tipo de diseño es el más adecuado para investigaciones de series temporales, ya que permite analizar la evolución de las variables a lo largo del tiempo sin manipulación del investigador. De acuerdo con Mairer et al. [7], la naturaleza no experimental garantiza que las variables independientes se recolectan tal como ocurren en su contexto real. Bajo este enfoque predictivo, se evaluó el rendimiento de los modelos mediante métricas propias de regresión y series temporales, como MAE, RMSE, R^2 y MAPE siendo este



último solo para evaluar series temporales. La presente investigación no formula una hipótesis debido a que se clasifica dentro del nivel descriptivo, cuyo propósito es identificar, caracterizar y registrar las propiedades de una o más variables tal como se presentan en un contexto determinado. Esto se sustenta en lo señalado por Gonzales [8] quienes explican que en los estudios descriptivos “las hipótesis no siempre son necesarias, ya que el objetivo central es especificar las características de variables o fenómenos sin buscar relaciones causales entre ellas.

3.2 Objetivos

Evaluar comparativamente el desempeño de los algoritmos CatBoost, XGBoost, Linear Regression y Prophet para la predicción de las exportaciones departamentales del Perú, con el fin de identificar el modelo más preciso y robusto que contribuya a la toma de decisiones en la gestión y promoción del comercio exterior regional.

3.3 Datos

El conjunto de datos cuenta con un total de un total de 450 filas por 17 columnas en las cuales se dividen en los siguientes 'Año', 'Productos tradicionales - Pesqueros', 'Productos tradicionales - Agrícolas', 'Productos tradicionales - Mineros', 'Productos tradicionales - Petróleo y gas natural', 'Productos no tradicionales - Agropecuarios', 'Productos no tradicionales - Pesqueros', 'Productos no tradicionales - Textiles', 'Productos no tradicionales - Maderas y papeles, y sus manufacturas', 'Productos no tradicionales - Químicos', 'Productos no tradicionales - Minerales no metálicos', 'Productos no tradicionales - Sidero-metalúrgicos y joyería', 'Productos no tradicionales - Metal-mecánicos', 'Productos no tradicionales - Otros', 'Otros', 'Total Exportaciones', 'Departamento', estos datos fueron extraídos de el BCRP [9], que proporciona los datos para este estudio donde se saca las exportaciones por departamentos en de manera anual desde el año 2005 hasta el 2022, para ello los datos obtenidos fueron sacados en formato CSV de manera que se hizo su respectiva limpieza de datos para su posterior uso para modelos de machine learning, el conjunto de datos se dividió en 80% para el entrenamiento y el 20% para la validación, siguiendo la recomendación metodológica de Lalwani et al [10] que esta proporción favorece un equilibrio adecuado entre el entrenamiento del modelo y la evaluación imparcial de su desempeño. En este sentido, los modelos se entrenaron utilizando el 80 % de los datos, reservando el 20 % restante como conjunto de prueba para asegurar una validación externa y prevenir el sobreajuste.

3.4 Selección de algoritmos

Se seleccionaron los 4 algoritmos para el uso en nuestro dataset

- **CatBoost:** Se escogió CatBoost porque su uso en la predicción de exportaciones y precios de exportación ha mostrado resultados superiores frente a métodos tradicionales y otros algoritmos de boosting, como el en siguiente estudio [11] procesa variables categóricas de forma nativa, evitando la necesidad de codificación manual y mejorando la precisión en contextos económicos y comerciales donde abundan este tipo de datos. En la figura 1 se muestra la arquitectura de CatBoost

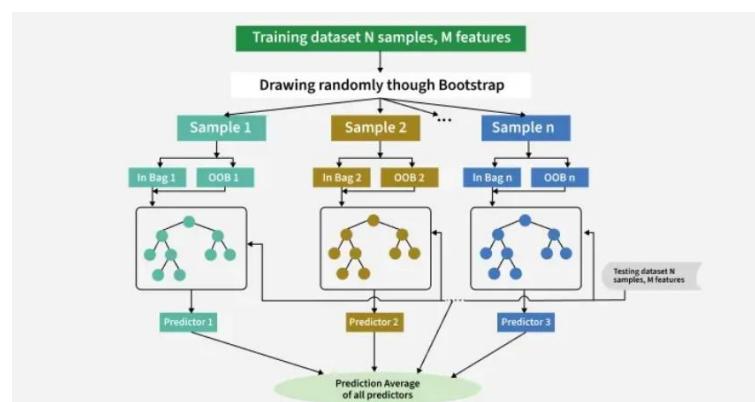


Fig 1. Estructura del algoritmo de CatBoost extraída de [12]

- **XGBoost:** Se escogió porque es uno de los algoritmos de machine learning más utilizados para predicción en series temporales y variables económicas, incluyendo exportaciones y precios de productos exportables. Su éxito se debe a su alta precisión, capacidad para manejar datos complejos y eficiencia computacional como en el siguiente estudio [13] donde superó a modelos tradicionales (ARIMA, LSTM, Random Forest) en la predicción de precios y volúmenes de exportación, especialmente cuando se combinan variables económicas, de tendencia y de mercado. En la figura 2 se muestra la arquitectura de XGBoost

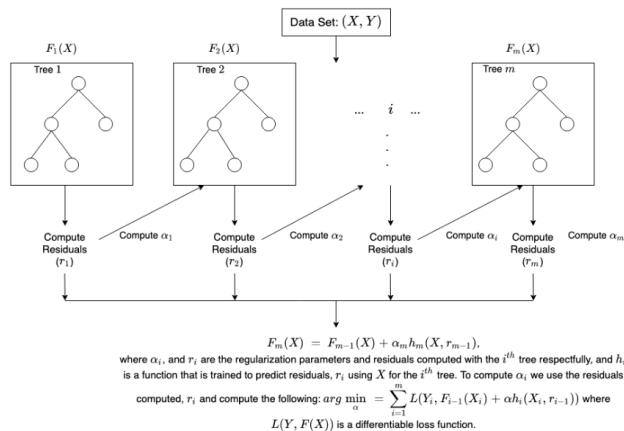


Fig 2: Estructura del algoritmo de XGBoost extraído de[14]

- **Prophet:** se escogió porque es un modelo de series temporales ampliamente utilizado para la predicción de exportaciones y precios de productos exportables, como en el siguiente estudio [15] donde ha demostrado ser preciso en la predicción de volúmenes y precios de exportación, como en el caso de las exportaciones de avellana en Turquía y productos agrícolas, superando a modelos tradicionales en algunos escenarios. En la figura 3 se muestra la arquitectura de Prophet

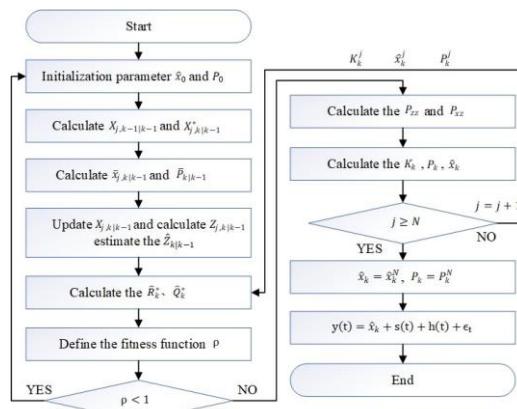


Fig 3: Estructura del algoritmo Prophet extraído de[16]

- **Linear Regression:** se utilizó porque se ha empleado exitosamente para analizar y predecir valores de exportación en diferentes regiones y departamentos. Por ejemplo, en Kalimantan Oriental y Kalimantan del Sur, la regresión lineal simple permitió identificar tendencias y realizar pronósticos precisos de exportaciones, con errores bajos (RMSE de 3.18%) y parámetros estadísticamente significativos[17]. En la figura 4 se muestra la arquitectura de Linear Regression

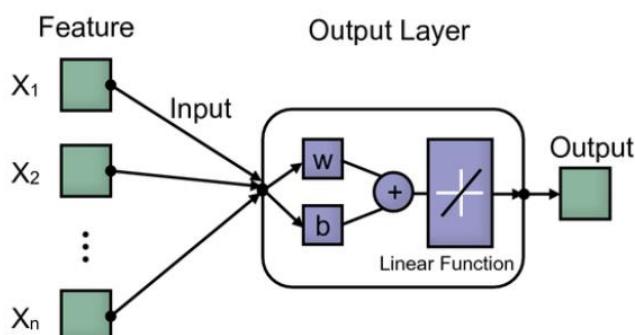


Fig 4: Estructura del algoritmo de regresión lineal extraído de[18]

3.5 Instrumentos y técnicas

Para la implementación de este estudio, se empleó Python como lenguaje de programación, aprovechando su versatilidad y el vasto soporte de bibliotecas especializadas en aprendizaje automático. El entrenamiento de los modelos se llevó a cabo en Google Colab, un entorno de desarrollo que proporcionó acceso a recursos de computación en la nube.

3.6 Preprocesamiento

El preprocesamiento se hizo de la siguiente manera

- Primero se descargaron todos los CSV y se eliminaron las columnas de total de productos exportados tradicionales y total de productos no tradicionales
- Lo segundo fue borrar los datos duplicados o nulos, se agregar la columna departamentos, y años se unió todo eso y redondeo los valores numéricos
- Y al final todos los datos se unió en un solo CSV

Para el entrenamiento y evaluación de los modelos de predicción, se llevó a cabo un proceso de preprocesamiento que permitió preparar adecuadamente las variables de entrada. En primer lugar, se definieron las variables independientes (features) y dependientes (targets). Las variables predictoras incluyeron el año y el departamento ($X = ["Año", "Departamento"]$), mientras que las variables dependientes correspondieron a los distintos tipos de productos exportados, agrupados en categorías tradicionales y no tradicionales, además del total de exportaciones.

Posteriormente, se diferenciaron las variables numéricas y categóricas para su tratamiento específico. La variable numérica (Año) fue escalada mediante la técnica StandardScaler, que normaliza los valores restando la media y dividiendo por la desviación estándar, lo que mejora la estabilidad numérica y la eficiencia del entrenamiento de los modelos. Por otro lado, la variable categórica (Departamento) fue codificada utilizando la técnica One-Hot Encoding, que transforma las categorías en variables binarias, permitiendo que los algoritmos manejen información cualitativa de manera cuantitativa sin introducir un orden artificial.

Estas transformaciones se integraron en un pipeline de preprocesamiento utilizando la clase ColumnTransformer, lo que garantizó un flujo de datos consistente, ordenado y reproducible durante todo el proceso de modelado. Asimismo, se empleó GridSearchCV en conjunto con el pipeline para identificar los mejores hiperparámetros de cada modelo. Este procedimiento incluyó validación cruzada, lo que permitió evaluar la estabilidad del rendimiento y seleccionar la configuración óptima, reduciendo el riesgo de sobreajuste y mejorando la capacidad predictiva del modelo.

Finalmente, los datos fueron divididos en un conjunto de entrenamiento (80 %) y un conjunto de validación (20 %) mediante la función `train_test_split`, manteniendo un criterio de aleatoriedad controlada (`random_state=42`). Esta partición permitió evaluar el desempeño de los modelos de forma objetiva y prevenir el sobreajuste (overfitting).

3.7 Análisis de datos

El análisis de datos se llevó a cabo mediante la comparación de las métricas de rendimiento de los modelos entrenados. Dado que el problema abordado corresponde a una tarea de regresión, se utilizaron exclusivamente métricas diseñadas para evaluar este tipo de modelos.

+

- **Mae:** Mean Absolute Error es el promedio de las diferencias absolutas entre los valores reales y los valores predichos. Indica cuánto se equivoca en promedio el modelo (sin importar el signo del error).

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

- **RMSE:** Root Mean Squared Error es similar al MAE penaliza más los errores grandes, ya que los errores se elevan al cuadrado antes de promediarse.

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

- **R²:** Coeficiente de Determinación Indica qué proporción de la variabilidad de los datos reales es explicada por el modelo. Va de 0 a 1, donde 1 significa predicción perfecta.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

- **MAPE:** Mean Absolute Percentage Error es una métrica de evaluación usada comúnmente para medir la precisión de los modelos de predicción, especialmente en contextos económicos, financieros y de series temporales [3], mientras que el valor este más cercano al 0 es mucho mejor el modelo

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

4. Resultados

Como el tipo de problema es de tiempos los resultados tuvieron que hacerse por departamentos y productos por lo cual se sacó la media aritmética para cada modelo para así determinar cuál fue el mejor modelo para predecir las exportaciones por departamentos, en total fueron 390 modelos evaluadas

4.1 Resultados de CatBoost

CatBoost se uso MultiOutputRegressor para múltiples salidas, los mejores parámetros fueron 1000 iteraciones, una profundidad máxima de 8 niveles y una tasa de aprendizaje de 0.05, además de técnicas de muestreo aleatorio (bootstrap_type=Bernoulli, subsample=0.8) para mejorar la generalización. Este modelo fue implementado dentro de un pipeline que integró el preprocesamiento y el entrenamiento de manera automatizada y reproducible. Durante el proceso de evaluación, se calcularon métricas como el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Coeficiente de Determinación (R^2) tanto para el conjunto de entrenamiento como para el de validación. A continuación, los siguientes resultados se muestra en la tabla 1

Tabla1. Resultados de desempeño del modelo CatBoost durante las fases de entrenamiento y validación.

Métricas	Entrenamiento	Validación
MAE	10.978598	32.918252
RMSE	41.431965	109.724267
R^2	99.6621%	96.2844%

4.2 Resultados de XGBoost

XGBoost se uso MultiOutputRegressor para múltiples salidas, los mejores parámetros fueron 1000 estimadores, una profundidad máxima de 6 árboles, una tasa de aprendizaje de 0.05, y la política de crecimiento lossguide, parámetros seleccionados para optimizar el equilibrio entre capacidad predictiva y eficiencia computacional. Durante el proceso de evaluación, se calcularon métricas como el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Coeficiente de Determinación (R^2) tanto para el conjunto de entrenamiento como para el de validación. A continuación, los siguientes resultados se muestra en la tabla 2

Tabla2. Resultados de desempeño del modelo XGBoost durante las fases de entrenamiento y validación

Métricas	Entrenamiento	Validación
MAE	3.869750	40.080151
RMSE	23.921365	163.583246
R^2	99.8873%	91.7414%

4.3 Resultados de LinearRegression

Para evaluar el desempeño se calcularon métricas como el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE), el Error Porcentual Absoluto Medio (MAPE) y el Coeficiente de Determinación (R^2). Los resultados mostraron que la Regresión Lineal obtuvo un rendimiento aceptable en categorías con tendencias temporales estables, aunque presentó limitaciones al modelar relaciones más complejas o no lineales entre los predictores y las exportaciones. Durante el proceso de evaluación, se calcularon métricas como el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Coeficiente de Determinación (R^2) tanto para el conjunto de entrenamiento como para el de validación. A continuación, los siguientes resultados se muestra en la tabla 3



Tabla3. Resultados de desempeño del modelo LinearRegression durante las fases de entrenamiento y validación

Métricas	Entrenamiento	Validación
MAE	86.516628	80.596246
RMSE	269.7688	236.624060
R ²	85.6739%	82.7200%

4.4 Resultados de Prophet

Se entrenaron modelos Prophet individualizados para cada combinación de departamento y categoría de producto, la división para este modelo fue la siguiente desde 2005 hasta 2018 se usaron para entrenar el modelo de ahí se usó para la validación se utilizó la librería train-test split temporal, con el fin de capturar las tendencias locales y específicas de cada sector. Para cada caso, se seleccionaron las variables Año (como variable temporal) y el valor correspondiente de exportaciones (como variable dependiente), las cuales fueron renombradas a los formatos requeridos por Prophet (ds y y). La columna temporal fue convertida al tipo datetime para permitir su procesamiento como serie temporal.

El modelo se configuró considerando únicamente estacionalidad anual, dado que las exportaciones se registran en períodos anuales, desactivando las componentes diaria y semanal. Posteriormente, se generaron predicciones a tres años futuros y se evaluó el rendimiento del modelo mediante las métricas MAE, RMSE y MAPE se aplicó para modelos de tipo series temporales, calculadas al comparar los valores observados con las predicciones del modelo.

Los resultados obtenidos se almacenaron por cada combinación de producto y departamento, permitiendo realizar un análisis comparativo del rendimiento del modelo en distintas regiones. En general, este procedimiento posibilitó evaluar la capacidad del modelo Prophet para representar de manera precisa las dinámicas temporales de las exportaciones regionales, garantizando además la reproducibilidad y consistencia del proceso.

A continuación, los siguientes resultados se muestra en la tabla 4

Tabla4. Resultados de desempeño del modelo Prophet durante las fases de entrenamiento y validación

Métricas	Entrenamiento	Validación
MAE	38.98938841	35.883826846
RMSE	51.27710616	72.15069058
MAPE	11.79223533	3.753737334

En la figura 4 muestra la comparación de los diferentes modelos de catBoost, XGBosst y LinnearRegression y sus métricas evaluadas que son MAE, RMSE y R²

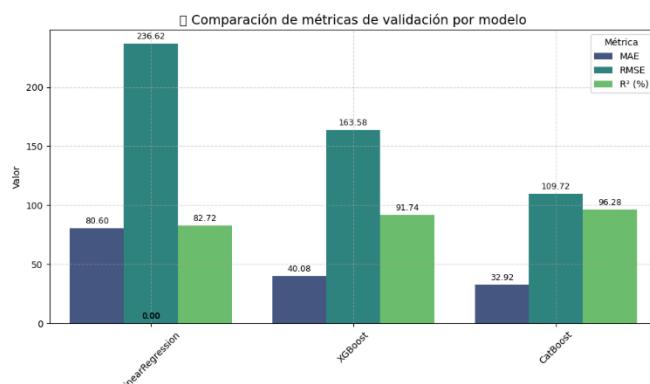


Fig 4. Comparación entre la métrica de validación entre los diferentes modelos

En la figura 5 se muestra las métricas que alcanzo el modelo Prophet

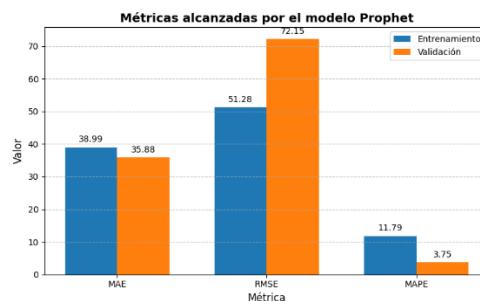


Fig 5. Comparación entre la métrica alcanzadas por prophet

4.5 Implementación del prototipo

El principal aporte práctico de esta investigación radica en el desarrollo de un prototipo funcional que se encuentra en el siguiente enlace <https://sistema-exportaciones-fullstack.vercel.app/> basado en el modelo Prophet, seleccionado por su destacado desempeño, evidenciado en sus bajos valores de MAE y RMSE, así como un MAPE del 3.75%, lo que refleja un margen de error reducido y una alta capacidad predictiva.

En total, se generaron 390 modelos, correspondientes a cada producto y departamento analizado.

La arquitectura del prototipo se presenta en la Figura 6. Este fue desarrollado bajo un entorno Django para el backend y React para el frontend. Finalmente, la interfaz de usuario puede apreciarse en la Figura 7.

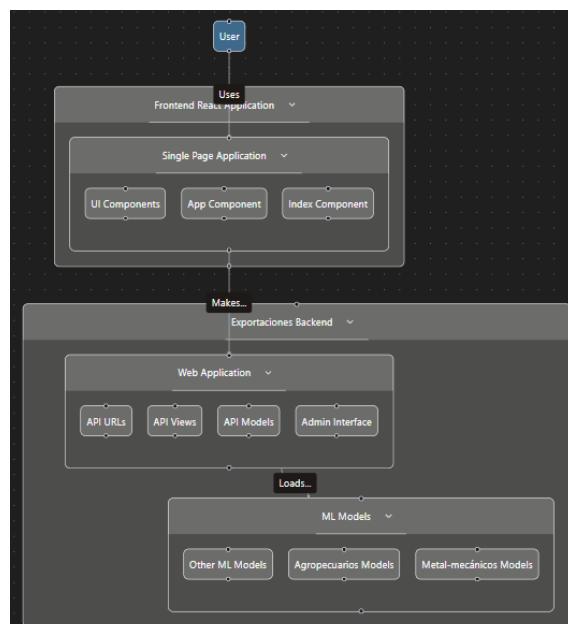


Fig 6. Diagrama del funcionamiento de la aplicación

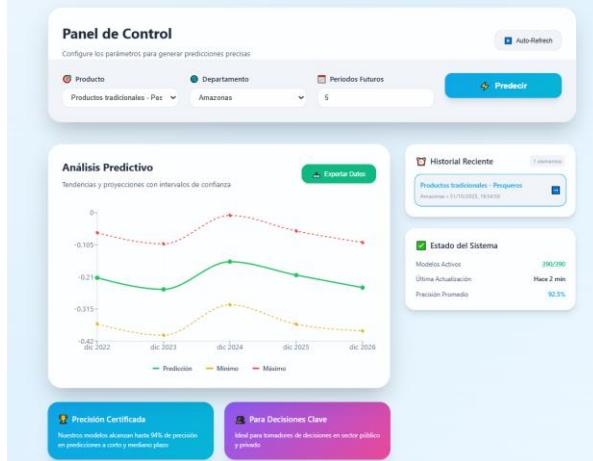


Fig 7. Interfaz de usuario

5. Discusiones y conclusión

Los resultados obtenidos en esta investigación evidencian una tendencia consistente con los hallazgos de estudios previos que aplicaron técnicas de machine learning en el ámbito de las exportaciones. En el trabajo de Gulzar et al. [4], las redes neuronales artificiales (ANN) mostraron un desempeño sobresaliente en la predicción de exportaciones de alta tecnología en Turquía, alcanzando un R^2 de 94.2 %, lo que respalda la capacidad de los modelos no lineales para representar relaciones económicas complejas. De manera similar, en este estudio, el modelo CatBoost demostró una excelente capacidad predictiva con un R^2 del 96.28 % y un MAE de 32.91, lo que confirma su eficacia en la identificación de patrones no lineales en las exportaciones regionales del Perú.

Por otro lado, los resultados de Sellami et al. [5] destacan el potencial de las Graph Neural Networks (GNN) en la modelación de relaciones comerciales internacionales, donde el modelo GAT alcanzó un R^2 de hasta 0.95, superando significativamente a métodos tradicionales como Random Forest ($R^2 = 0.64$). Esta superioridad de los modelos basados en aprendizaje profundo es coherente con el rendimiento del CatBoost en el presente estudio, evidenciando que los algoritmos que incorporan estructuras jerárquicas y manejo avanzado de variables categóricas tienden a ofrecer mayor precisión y generalización en contextos comerciales y económicos.

Asimismo, el trabajo de Kumar et al. [6] refuerza la superioridad de los algoritmos de machine learning frente a los modelos clásicos de series temporales como ARIMA o Double Exponential Smoothing. En su estudio sobre MIPYMES, Random Forest y XGBoost alcanzaron R^2 de 0.9973 y 0.9983, respectivamente, superando ampliamente los métodos tradicionales. De manera análoga, los resultados del presente trabajo confirman que CatBoost y Prophet superan en desempeño a la Regresión Lineal, la cual obtuvo un R^2 de 82.72 % y un RMSE de 236.62, mostrando limitaciones para capturar patrones no lineales en los datos de exportaciones.

En cuanto al modelo Prophet, sus resultados ($MAE = 35.88$, $RMSE = 72.15$ y $MAPE = 3.75\%$) muestran una notable estabilidad y una excelente capacidad para capturar tendencias y estacionalidades, en concordancia con su efectividad previamente reportada en estudios sobre predicción de exportaciones agrícolas y de commodities. Estos resultados sugieren que Prophet es particularmente adecuado para series temporales anuales y contextos donde se prioriza la interpretación y la proyección de tendencias.

El presente estudio demuestra que la aplicación de modelos de machine learning permite mejorar significativamente la precisión en la predicción de exportaciones por departamentos en el Perú, contribuyendo así al análisis regional del comercio exterior. Entre los modelos evaluados, CatBoost alcanzó el mejor rendimiento general, con un R^2 del 96.28 % y un MAE de 32.91, evidenciando su capacidad para representar relaciones no lineales y complejas entre las variables económicas y territoriales. Por su parte, el modelo Prophet presentó una notable estabilidad en la predicción de series temporales, con un MAPE de 3.75%, lo que lo posiciona como una herramienta robusta para capturar tendencias y estacionalidades del comportamiento exportador a nivel regional.

Finalmente, el desarrollo de un prototipo funcional basado en Prophet, integrado con Django y React, demuestra la aplicabilidad práctica de este enfoque, facilitando la visualización y proyección de exportaciones de manera dinámica y escalable. Se recomienda, como línea futura de investigación, incorporar variables macroeconómicas externas —como tipo de cambio, inversión extranjera y precios internacionales y explorar arquitecturas de aprendizaje profundo (LSTM, GNN o híbridos) para fortalecer la capacidad predictiva y la toma de decisiones estratégicas en políticas de desarrollo comercial.

6. Referencias

- [1] P. Suler, Z. Rowland, y T. Krulicky, «Evaluation of the Accuracy of Machine Learning Predictions of the Czech Republic's Exports to the China», *Journal of Risk and Financial Management*, vol. 14, n.o 2, feb. 2021, doi: 10.3390/jrfm14020076.
- [2] H. Jošić y B. Žmuk, «A Machine Learning Approach to Forecast International Trade: The Case of Croatia», *Business Systems Research*, vol. 13, n.o 3, pp. 144-160, oct. 2022, doi: 10.2478/bsrj-2022-0030.
- [3] M. Iaousse, Y. Jouilil, M. Bouincha, y D. Mentagui, «A Comparative Simulation Study of Classical and Machine Learning Techniques for Forecasting Time Series Data», *International journal of online and biomedical engineering*, vol. 19, n.o 8, pp. 56-65, 2023, doi: 10.3991/ijoe.v19i08.39853.
- [4] Y. Gulzar et al., «Predicting High Technology Exports of Countries for Sustainable Economic Growth by Using Machine Learning Techniques: The Case of Turkey», *Sustainability* 2024, Vol. 16, Page 5601, vol. 16, n.o 13, p. 5601, jun. 2024, doi: 10.3390/SU16135601.
- [5] B. Sellami, C. Ounoughi, T. Kalvet, M. Tiits, y D. Rincon-Yanez, «Harnessing Graph Neural Networks to Predict International Trade Flows», *Big Data and Cognitive Computing*, vol. 8, n.o 6, jun. 2024, doi: 10.3390/bdcc8060065.
- [6] S. K. R, B. M.S., y V. Pachava, «Machine Learning-Driven Export Forecasting: A Comparative Analysis for MSME Growth», *Journal of Economics, Innovative Management and Entrepreneurship*, vol. 3, n.o 1, feb. 2025, doi: 10.59652/JEIME.V3I1.401.
- [7] C. Maier, J. B. Thatcher, V. Grover, y Y. K. Dwivedi, «Cross-sectional research: A critical perspective, use cases, and recommendations for IS research», *Int J Inf Manage*, vol. 70, p. 102625, jun. 2023, doi: 10.1016/J.IJINFOMGT.2023.102625.
- [8] M. González Mares, «Hernández-Sampieri, R. & Mendoza, C (2018). Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta», *Revista Universitaria Digital de Ciencias Sociales (RUDICS)*, vol. 10, n.o 18, pp. 92-95, ene. 2019, doi: 10.22201/FESC.20072236E.2019.10.18.6.
- [9] «Exportaciones e importaciones». Accedido: 25 de octubre de 2025. [En línea]. Disponible en: <https://estadisticas.bcrp.gob.pe/estadisticas/series/anuales/exportaciones-e-importaciones>
- [10] F. H. Garabaghi, S. Benzer, y R. Benzer, «Modeling dissolved oxygen concentration using machine learning techniques with dimensionality reduction approach», *Environ Monit Assess*, vol. 195, n.o 7, pp. 1-23, jul. 2023, doi: 10.1007/S10661-023-11492-3/METRICS.
- [11] J. K. Sayyad, K. Attarde, y N. Saadouli, «Optimizing e-Commerce Supply Chains With Categorical Boosting: A Predictive Modeling Framework», *IEEE Access*, vol. 12, pp. 134549-134567, 2024, doi: 10.1109/ACCESS.2024.3447756.
- [12] «CatBoost in Machine Learning - GeeksforGeeks». Accedido: 25 de octubre de 2025. [En línea]. Disponible en: <https://www.geeksforgeeks.org/machine-learning/catboost-ml/>
- [13] T. Zhao, G. Chen, S. Suraphee, T. Phoophiwfa, y P. Busababodhin, «A hybrid TCN-XGBoost model for agricultural product market price forecasting», *PLoS One*, vol. 20, n.o 5, p. e0322496, may 2025, doi: 10.1371/JOURNAL.PONE.0322496.
- [14] «Cómo funciona el XGBoost algoritmo de SageMaker IA - Amazon SageMaker AI». Accedido: 25 de octubre de 2025. [En línea]. Disponible en: https://docs.aws.amazon.com/es_es/sagemaker/latest/dg/xgboost-HowItWorks.html
- [15] E. Aytaç, «Forecasting Turkey's Hazelnut Export Quantities with Facebook's Prophet Algorithm and Box-Cox Transformation», *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 10, n.o 1, pp. 33-47, feb. 2021, doi: 10.14201/ADCAIJ20211013347.
- [16] C. Guo, Q. Ge, H. Jiang, G. Yao, y Q. Hua, «Maximum Power Demand Prediction Using Fbprophet with Adaptive Kalman Filtering», *IEEE Access*, vol. 8, pp. 19236-19247, 2020, doi: 10.1109/ACCESS.2020.2968101.
- [17] A. B. Fawait, S. Rahmah, A. Diana, S. Da Costa, N. Insyroh, y A. A. Firdaus, «Implementation of Data Mining Using Simple Linear Regression Algorithm to Predict Export Values», *Scientific Journal of Engineering Research*, vol. 1, n.o 1, pp. 26-32, ene. 2025, doi: 10.64539/SJER.V1I1.2025.11.
- [18] D. H. Min y H. K. Yoon, «Suggestion for a new deterministic model coupled with machine learning techniques for landslide susceptibility mapping», *Sci Rep*, vol. 11, n.o 1, dic. 2021, doi: 10.1038/S41598-021-86137-X.